



ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ
ΠΡΟΒΛΕΨΗ ΠΑΡΑΓΩΓΗΣ ΕΝΕΡΓΕΙΑΣ ΑΠΟ
ΑΝΕΜΟΓΕΝΝΗΤΡΙΕΣ

ΕΠΙΜΕΛΕΙΑ
ΜΙΤΣΗΓΙΩΡΓΗΣ ΑΛΕΞΑΝΔΡΟΣ

A.M. : 2004010110

ΕΠΙΒΛΕΠΩΝ ΚΑΘΗΓΗΤΗΣ
ΑΤΣΑΛΑΚΗΣ ΓΕΩΡΓΙΟΣ

Τριμελής εξεταστική επιτροπή

Ατσαλάκης Γεώργιος
Αναπληρωτής Καθηγητής

Τσαφάρakis Στέλιος
Αναπληρωτής Καθηγητής

Κρασαδάκη Ευαγγελία
ΕΔΙΠ

Χανιά, Φεβρουάριος 2024



**ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ
ΠΡΟΒΛΕΨΗ ΠΑΡΑΓΩΓΗΣ ΕΝΕΡΓΕΙΑΣ ΑΠΟ
ΑΝΕΜΟΓΕΝΝΗΤΡΙΕΣ**



**ΕΠΙΜΕΛΕΙΑ
ΜΙΤΣΗΓΙΩΡΓΗΣ ΑΛΕΞΑΝΔΡΟΣ**

A.M. : 2004010110

**ΕΠΙΒΛΕΠΩΝ ΚΑΘΗΓΗΤΗΣ
ΑΤΣΑΛΑΚΗΣ ΓΕΩΡΓΙΟΣ**

Χανιά, Φεβρουάριος 2024

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ
ΠΡΟΒΛΕΨΗ ΠΑΡΑΓΩΓΗΣ ΕΝΕΡΓΕΙΑΣ ΑΠΟ
ΑΝΕΜΟΓΕΝΝΗΤΡΙΕΣ

ΕΠΙΜΕΛΕΙΑ
ΜΙΤΣΗΓΙΩΡΓΗΣ ΑΛΕΞΑΝΔΡΟΣ

Α.Μ. : 2004010110

ΕΠΙΒΛΕΠΩΝ ΚΑΘΗΓΗΤΗΣ
ΑΤΣΑΛΑΚΗΣ ΓΕΩΡΓΙΟΣ

Εγκρίθηκε από την τριμελή εξεταστική επιτροπή την 03/06/24

Ατσαλάκης Γεώργιος

Αναπληρωτής Καθηγητής

Τσαφάρakis Στέλιος

Αναπληρωτής Καθηγητής

Κρασαδάκη Ευαγγελία

ΕΔΙΠ

Χανιά, Φεβρουάριος 2024

Μιτσηγιώργης Αλέξανδρος

Διπλωματούχος Μηχανικός Παραγωγής και Διοίκησης Πολυτεχνείου Κρήτης

Copyright © Μιτσηγιώργης Αλέξανδρος, 2024

Με επιφύλαξη παντός δικαιώματος. All rights reserved.

Απαγορεύεται η αντιγραφή, αποθήκευση και διανομή της παρούσας εργασίας, εξ ολοκλήρου ή τμήματος αυτής, για εμπορικό σκοπό. Επιτρέπεται η ανατύπωση, αποθήκευση και διανομή για σκοπό μη κερδοσκοπικό, εκπαιδευτικής ή ερευνητικής φύσης, υπό την προϋπόθεση να αναφέρεται η πηγή προέλευσης και να διατηρείται το παρόν μήνυμα. Ερωτήματα που αφορούν τη χρήση της εργασίας για κερδοσκοπικό σκοπό πρέπει να απευθύνονται προς τους συγγραφείς.

Οι απόψεις και τα συμπεράσματα που περιέχονται σε αυτό το έγγραφο εκφράζουν τους συγγραφείς και δεν πρέπει να ερμηνευθεί ότι αντιπροσωπεύουν τις επίσημες θέσεις του Πολυτεχνείου Κρήτης.

ΕΥΧΑΡΙΣΤΙΕΣ

Θα ήθελα να ευχαριστήσω θερμά τον επιβλέποντα καθηγητή κ. Ατσαλάκη Γεώργιο και να εκφράσω τη βαθιά μου ευγνωμοσύνη στην οικογένεια μου.

Τόσο η καθοδήγηση όσο και η στήριξη τους κατά τη διάρκεια της διπλωματικής μου εργασίας, με βοήθησαν να ολοκληρώσω επιτυχώς αυτό το σημαντικό εγχείρημα.

Μιτσηγιώργης Αλέξανδρος

ΠΕΡΙΛΗΨΗ

Η στροφή των τελευταίων ετών προς τις ανανεώσιμες πηγές ενέργειας με κορυφαία στη λίστα την αιολική ενέργεια, αποτελεί ουσιαστικό παράγοντα της βιώσιμης ανάπτυξης. Στο πεδίο της αιολικής ενέργειας συναντάμε πληθώρα πλεονεκτημάτων. Με στόχο την βελτιστοποίηση της αποδοτικότητας, το ενδιαφέρον στρέφεται στην σημασία πρόβλεψης παραγωγής ηλεκτρικής ενέργειας επικεντρώνοντας ιδιαιτέρως στον βραχυπρόθεσμο ορίζοντα πρόβλεψης μιας ημέρας. Στην παρούσα εργασία αναλύονται οι χρονικές παράμετροι, τα στάδια και τα πλεονεκτήματα του βραχυπρόθεσμου ορίζοντα πρόβλεψης. Γίνεται μια ανασκόπηση των μοντέλων πρόβλεψης, η οποία καλύπτει παραδοσιακές μεθόδους έως σύγχρονες τεχνικές.

Για τον σκοπό της πρόβλεψης παραγωγής ηλεκτρικής ενέργειας από ανεμογεννήτριες, επιλέγεται η μέθοδος ANFIS (Adaptive Neuro – Fuzzy Inference System) η οποία αντιπροσωπεύει το Προσαρμοστικό Σύστημα Νευρο – ασαφούς Συμπερασμού και πρόκειται για ένα υβριδικό μοντέλο που συνδυάζει δύο ευφυή συστήματα: την μάθηση των Τεχνητών Νευρωνικών Δικτύων (ANN) με τις ικανότητες συλλογισμού της Ασαφούς Λογικής (Fuzzy Logic) και πιο συγκεκριμένα τα Συστήματα Ασαφών Συμπερασμάτων (FISs Fuzzy Inference Systems). Καθώς η μέθοδος ANFIS αποτελεί ισχυρό εργαλείο πρόβλεψης γίνεται μια εκτενής περιγραφή των χαρακτηριστικών της όπως η αρχιτεκτονική, οι μέθοδοι μάθησης, οι εφαρμογές, τα πλεονεκτήματα, τα μειονεκτήματα και οι περιορισμοί της.

Στο τεχνικό κομμάτι της εργασίας, καταχωρούνται στο μοντέλο ANFIS πιστοποιημένες μετρήσεις για 365 μέρες, από τέσσερις ανεμογεννήτριες από αιολικό πάρκο σε νησί της Ελλάδας. Γίνεται περιγραφή των μοντέλων πρόβλεψης, αναλύεται το στάδιο εκπαίδευσης, οι κανόνες και η δομή, παρουσιάζονται τα δεδομένα παραγωγής ηλεκτρικής ενέργειας, τα διαγράμματα δεδομένων εκπαίδευσης, τα χαρακτηριστικά και οι κανόνες των μοντέλων ANFIS, τα διαγράμματα θέασης, η πρόβλεψη μοντέλων ANFIS και τέλος τα συμπεράσματα και η αξιολόγηση των μοντέλων πρόβλεψης.

Συνοπτικά, η παρούσα διατριβή αποσκοπεί στην αποκάλυψη των πολυπλοκοτήτων σχετικά με την πρόβλεψη της αιολικής ενέργειας και στην δημιουργία προϋποθέσεων για την λήψη αποφάσεων στον κλάδο της ανανεώσιμης ενέργειας.

Λέξεις – κλειδιά: αιολική ενέργεια, πρόβλεψη, ανεμογεννήτρια, ασαφής λογική, νευρωνικά δίκτυα, νευρο-ασαφή δίκτυα, ANFIS, μοντέλο πρόβλεψης, παραγωγή ηλεκτρικής ενέργειας, πρόβλεψη επόμενης ημέρας, σφάλμα πρόβλεψης

ABSTRACT

The shift towards renewable energy sources in recent years, with wind energy leading the list, constitutes a vital factor for sustainable development. In the field of wind energy, numerous advantages are encountered. With the aim of optimizing efficiency, attention is drawn to the importance of electricity production prediction, particularly focusing on short-term forecasting for one day ahead. This thesis analyzes the temporal parameters, stages, and advantages of short-term prediction horizon.

A review of prediction models is provided, covering traditional methods to modern techniques. For the purpose of predicting electricity generation from wind turbines, the Adaptive Neuro-Fuzzy Inference System (ANFIS) method is selected. ANFIS is a hybrid model combining two intelligent systems: the learning of Artificial Neural Networks (ANN) with the reasoning abilities of Fuzzy Logic, specifically Fuzzy Inference Systems (FISs). As the ANFIS method constitutes a powerful prediction tool, a detailed description of its characteristics, including architecture, learning methods, applications, advantages, disadvantages, and limitations, is presented.

In the technical part of the work, certified measurements for 365 days from four wind turbines in a wind park on a Greek island are incorporated into the ANFIS model. A description of the prediction models, analysis of the training stage, rules and structure, presentation of electricity production data, training data diagrams, characteristics and rules of the ANFIS models, visualization diagrams, ANFIS model prediction, and finally conclusions and evaluation of the prediction models are provided.

In summary, this thesis aims to unravel the complexities surrounding wind energy prediction and create conditions for decision-making in the renewable energy sector.

Keywords: wind energy, forecasting, wind turbine, fuzzy logic, neural networks, neuro-fuzzy networks, ANFIS, forecasting model, electric power generation, one step ahead, prediction error

ΠΕΡΙΕΧΟΜΕΝΑ

ΚΕΦΑΛΑΙΟ 1 ^ο – ΕΙΣΑΓΩΓΗ	3
1.1 Αιολική Ενέργεια	3
1.1.1 Ορισμός	3
1.1.2 Βασικές Αρχές	4
1.1.3 Αποδοτικότητα	4
1.1.4 Πλεονεκτήματα	5
1.1.5 Έκθεση Ευρωπαϊκής Ένωσης Αιολικής Ενέργειας (EWEA) 2022	6
1.2 Η Σημασία της Πρόβλεψης	6
1.3 Βραχυπρόθεσμος Χρονικός Ορίζοντας Πρόβλεψης 1 Ημέρας	7
1.3.1 Χρονικοί Ορίζοντες	8
1.3.2 Στάδια Βραχυπρόθεσμης Πρόβλεψης (Short – Term One Day ahead)	9
1.3.3 Πλεονεκτήματα Βραχυπρόθεσμης Πρόβλεψης (Short – Term One Day ahead)	9
1.4 Ανασκόπηση Μοντέλων Πρόβλεψης	11
1.4.1 Προσέγγιση με την Μέθοδο Παραμένουσας Πρόβλεψης (Persistent Method)	11
1.4.2 Φυσική Προσέγγιση (Physical Approach)	12
1.4.3 Στατιστικές Προσεγγίσεις (Statistical Approaches)	12
1.4.4 Προσέγγιση μέσω Νέων Τεχνικών (New Techniques Approach)	14
1.4.5 Προσέγγιση με Υβριδικές Δομές (Hybrid Structures Approach)	14
1.5 Μέθοδος ANFIS για Πρόβλεψη	15
1.5.1 Επίπεδα Αρχιτεκτονικής ANFIS	16
1.5.2 Εφαρμογές ANFIS	17
ΚΕΦΑΛΑΙΟ 2 ^ο – ΑΣΑΦΗΣ ΛΟΓΙΚΗ	21
2.1 Εισαγωγή στην Ασαφή Λογική	21
2.1.1 Γενικά	21
2.1.2 Ασαφή Σύνολα	22
2.1.3 Διαχωρισμός Ασαφούς Λογικής – Θεωρίας Πιθανοτήτων	24
2.2 Εφαρμογές, πλεονεκτήματα και περιορισμοί	25
2.2.1 Πλεονεκτήματα Ασαφούς Λογικής	25
2.2.2 Περιορισμοί Ασαφούς Λογικής	26
2.3 Ασαφή Σύνολα και Συναρτήσεις Συμμετοχής	27

2.3.1 Ασαφές Σύνολο – Ορισμός	27
2.3.2 Μορφές Συναρτήσεων Συμμετοχής	30
2.3.3 Κατασκευή Συναρτήσεων Συμμετοχής	33
2.4 Ιδιότητες και Λογικές Πράξεις	35
2.4.1 Ιδιότητες Ασαφών Συνόλων	35
2.4.2 Λογικές Πράξεις Ασαφών Συνόλων	37
2.4.3 Ασαφής Σχέσεις	41
2.5 Ασαφής Συλλογιστική και Ασαφείς Κανόνες	42
2.6 Ασαφή Συστήματα Συμπερασμού (Fuzzy Inference Systems – FIS)	45
2.7 Ασαφές Σύστημα Συμπερασμού Takagi – Sugeno – Kang (TSK)	48
ΚΕΦΑΛΑΙΟ 3ο – ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ	55
3.1 Εισαγωγή στα Νευρωνικά Δίκτυα	55
3.2 Βιολογικός Νευρώνας	55
3.3 Τεχνητά Νευρωνικά Δίκτυα - ΤΝΔ	56
3.3.1 Ορισμός – Χαρακτηριστικά – Κατηγοριοποιήσεις ΤΝΔ	56
3.3.2 Αρχιτεκτονική ΤΝΔ	61
3.3.3 Διαδικασία Μάθησης και Ικανότητα Γενίκευσης των ΤΝΔ	67
3.3.4 Κύρια Χαρακτηριστικά ΤΝΔ	74
3.3.5 Εφαρμογές ΤΝΔ	76
3.4 Νευρο – Ασαφή Συστήματα	77
3.4.1 Ασαφείς Νευρώνες	77
3.4.2 Προσαρμοστικά Δίκτυα (Adaptive Networks)	79
3.4.3 Αρχιτεκτονική Προσαρμοστικών Δικτύων	80
3.4.4 Καταμερισμός Παραμέτρων στο Δίκτυο	81
3.4.5 Παραδείγματα Προσαρμοστικών Δικτύων	83
ΚΕΦΑΛΑΙΟ 4ο – ΜΕΘΟΔΟΣ ANFIS	89
4.1 Εισαγωγικά	89
4.2 Δίκτυο ANFIS και Νευρώνες	90
4.3 Σχέση Προσαρμοστικών Δικτύων και ANFIS	92
4.4 Υβριδικός Κανόνας Μάθησης (Hybrid Learning Algorithm) Batch Learning (Off-Line)	95
4.5 Σχέση Μεταξύ ANFIS και Ασαφούς Μοντέλου Takagi – Sugeno – Kang (TSK)	98
4.6 Αρχιτεκτονική του ANFIS	100
4.7 Εκτιμητής Ελαχίστων Τετραγώνων (Least – Squares Estimator)	104

4.8 Οπισθόδρομη Εκμάθηση για Έμπροσθεν – Τροφοδοτούμενα Δίκτυα (ANFIS)	106
4.9 Συνδυασμός Βαθμωτής Ελαχιστοποίησης & Εκτιμητή Ελαχίστων Τετραγώνων	113
4.10 Πλεονεκτήματα, Μειονεκτήματα και Περιορισμοί του ANFIS	116
ΚΕΦΑΛΑΙΟ 5ο – ΑΠΟΤΕΛΕΣΜΑΤΑ ANFIS	121
5.1 Αποτελέσματα από την χρήση του μοντέλου ANFIS	121
5.1.1 Βάση Δεδομένων	121
5.1.2 Περιγραφή Μοντέλων Πρόβλεψης	121
5.1.3 Επιλογή Συναρτήσεων Συμμετοχής (Membership Function/MF)	122
5.1.4 Στάδιο Εκπαίδευσης	123
5.1.5 Κανόνες (Rules) και Δομή Μοντέλων ANFIS	127
5.1.6 Δεδομένα Παραγωγής Ηλεκτρικής Ενέργειας από Ανεμογεννήτρια 4	129
5.1.7 Διαγράμματα Δεδομένων Εκπαίδευσης	130
5.1.8 Διαγράμματα Διασποράς Δεδομένων Αξιολόγησης	131
5.1.9 Χαρακτηριστικά Μοντέλων ANFIS	132
5.1.10 Μορφή Κανόνων (Rule Viewer)	133
5.1.11 Διαγράμματα Θέασης (ANFIS Surface Viewer)	134
5.1.12 Πρόβλεψη Μοντέλων ANFIS	136
5.1.13 Αξιολόγηση των Μοντέλων Πρόβλεψης	138
ΚΕΦΑΛΑΙΟ 6ο – ΣΥΜΠΕΡΑΣΜΑΤΑ	143
ΒΙΒΛΙΟΓΡΑΦΙΑ	147
ΠΑΡΑΡΤΗΜΑ	151

ΛΙΣΤΑ ΕΙΚΟΝΩΝ

Εικόνα 1. 1 Διαδικασία Παραγωγής Ηλεκτρικής Ενέργειας από Αιολική	3
Εικόνα 2.1 Ακρίβεια VS Σημαντικότητα	21
Εικόνα 3.1 Δομή Βιολογικού Νευρώνα	56
Εικόνα 3.2 Επιβλεπόμενη Μάθηση	68
Εικόνα 3.3 Ενισχυτική Μάθηση	68
Εικόνα 3.4 Μάθηση Χωρίς Επίβλεψη	69
Εικόνα 3.5 Ημιεπιβλεπόμενη Μάθηση	69
Εικόνα 3.6 Αυτοεποπτική Μάθηση	70
Εικόνα 5.1 ANFIS 2 Matlab – Δομή Τεσσάρων Κανόνων	127
Εικόνα 5.2 ANFIS 2 Matlab – Αρχιτεκτονική ANFIS 2	128
Εικόνα 5.3 ANFIS 3 Matlab – Δομή Οκτώ Κανόνων	128
Εικόνα 5.4 ANFIS 3 Matlab – Αρχιτεκτονική ANFIS 3	129
Εικόνα 5.5 ANFIS 2	132
Εικόνα 5.6 ANFIS 3	132

ΛΙΣΤΑ ΣΧΗΜΑΤΩΝ

Σχήμα 1.1 Πλεονεκτήματα Αιολικής Ενέργειας	5
Σχήμα 1.2 Οφέλη Πρόβλεψης Αιολικής Ενέργειας	7
Σχήμα 2.1 Η Κλασσική Λογική Υποσύνολο της Ασαφούς	22
Σχήμα 2.2 Σχηματική Αναπαράσταση Συμβατικού και Ασαφούς Συνόλου	24
Σχήμα 2.3 Διαδικασία Ασαφούς Συλλογιστικής	43
Σχήμα 2.4 Κανόνες if – then στην Ασαφή Λογική	45
Σχήμα 2.5 Δομή Ασαφούς Συστήματος Συμπερασμού	46
Σχήμα 2.6 Δομή Ασαφούς Συστήματος Συμπερασμού	47
Σχήμα 2.7 Ασαφές Μοντέλο Sugeno Πρώτου Βαθμού	49
Σχήμα 2.8 Ασαφές Μοντέλο Sugeno, Δύναμη Πυροδότησης	50
Σχήμα 2.9 Ασαφές Σύστημα Συμπερασμού Takagi – Sugeno – Kang (TSK)	
Ποσοστό Φιλοδωρήματος	50
Σχήμα 2.10 Επιφάνεια της Λύσης του Προβλήματος Φιλοδώρημα	51
Σχήμα 3.1 Απλός Τεχνητός Νευρώνας	59
Σχήμα 3.2 Απλό Νευρωνικό Δίκτυο	60
Σχήμα 3.3 Δομή Δικτύου Υπολογιστικού Νευρώνα	61
Σχήμα 3.4 Μονοστρωματικό ΤΝΔ	63
Σχήμα 3.5 Μονοστρωματικό Δίκτυο Τύπου Hopfield	64
Σχήμα 3.6 Πολυστρωματικό ΤΝΔ	65
Σχήμα 3.7 Ανταγωνιστικό Επίπεδο	65
Σχήμα 3.8 ΤΝΔ Ανατροφοδότησης	66
Σχήμα 3.9 Συμμετρικό αυτόσυσχετιστικό ΤΝΔ	67

Σχήμα 3.10 Ασαφείς Νευρώνες	78
Σχήμα 3.11 Feed – Forward Προσαρμοστικό Δίκτυο με Επίπεδα	81
Σχήμα 3.12 (α) Ένας Μονός Κόμβος (b) Ένα Πρόβλημα έχει Κοινές Παραμέτρους	81
Σχήμα 3.13 Εμπροσθόδρομο Προσαρμοστικό Δίκτυο	82
Σχήμα 3.14 Επαναληπτικό Προσαρμοστικό Δίκτυο	82
Σχήμα 3.15 Γραμμικό Προσαρμοστικό Δίκτυο με Ένα κόμβο	84
Σχήμα 3.16 Μη Γραμμικό Προσαρμοστικό Δίκτυο με Έναν Κόμβο	84
Σχήμα 3.17 Πολυεπίπεδο Perceptron	85
Σχήμα 4.1 Δίκτυο ANFIS	90
Σχήμα 4.2 Προσαρμοστικό Δίκτυο	93
Σχήμα 4.3 Ασαφής Συλλογιστική (Fuzzy Reasoning)	100
Σχήμα 4.4 Η Αρχιτεκτονική Δομή του ANFIS	101
Σχήμα 4.5 Η Αρχιτεκτονική του ANFIS για το Ασαφές Σύνολο Sugeno - Κανονικοποίηση στο Τελευταίο Επίπεδο	103
Σχήμα 4.6 (α) Η αρχιτεκτονική του ANFIS για το ασαφές μοντέλο κατά Sugeno με δύο εισόδους και εννέα κανόνες (b) ο χώρος εισόδου, χωρισμένος σε εννέα ασαφείς περιοχές	104
Σχήμα 4.7 Το Προσαρμοστικό Δίκτυο	111
Σχήμα 4.8 Το Δίκτυο Διάδοσης Σφάλματος	111

ΛΙΣΤΑ ΠΙΝΑΚΩΝ

Πίνακας 1.1 Χρονικοί Ορίζοντες Πρόβλεψης και Εφαρμογές	8
Πίνακας 1.2 Πλεονεκτήματα Βραχυπρόθεσμης Πρόβλεψης	11
Πίνακας 2.1 Κλασσικά VS Ασαφή Σύνολα	27
Πίνακας 2.2 Λογικοί Τελεστές AND, OR, NOT στην Λογική Boole	37
Πίνακας 2.3 Λογικοί Τελεστές AND, OR, NOT στην Ασαφή Λογική	38
Πίνακας 4.1 Δραστηριότητες κατά την Εκπαίδευση	114
Πίνακας 5.1 Μοντέλα ANFIS	122
Πίνακας 5.2 ANFIS 2 Εισόδων – MSE – RMSE – MAE – MAPE	139
Πίνακας 5.3 ANFIS 3 Εισόδων – MSE – RMSE – MAE – MAPE	139

ΛΙΣΤΑ ΔΙΑΓΡΑΜΜΑΤΩΝ

Διάγραμμα 1.1 Αρχιτεκτονική ANFIS	16
Διάγραμμα 2.1 Συνάρτηση Συμμετοχής που Χαρακτηρίζει το Υποσύνολο της «Καλής» Ποιότητας Εξυπηρέτησης	23
Διάγραμμα 2.2 Δυαδική Λογική VS Ασαφή Λογική	29
Διάγραμμα 2.3 Γραφική Παράσταση Χρόνου Συνεχούς Κλίμακας Σαββατοκύριακου	29
Διάγραμμα 2.4 Τριγωνική Συνάρτηση Συμμετοχής	30

Διάγραμμα 2.5 Τραπεζοειδής Συνάρτηση Συμμετοχής	31
Διάγραμμα 2.6 Γκαουσιανές Συναρτήσεις Συμμετοχής	31
Διάγραμμα 2.7 Καμπανοειδής Συνάρτηση Συμμετοχής	32
Διάγραμμα 2.8 Σιγμοειδής Συναρτήσεις Συμμετοχής	32
Διάγραμμα 2.9 Πολυωνυμικές Καμπύλες Z, S, Π	33
Διάγραμμα 2.10 Ελαστικότητα ως προς τον Χαρακτηρισμό «Μεσαία»	33
Διάγραμμα 2.11 Αυστηρότητα ως προς τον Χαρακτηρισμό «Μεσαία»	34
Διάγραμμα 2.12 Συμμετρία Συνάρτησης Συμμετοχής	35
Διάγραμμα 2.13 Γραφική Απεικόνιση Τελεστών στην Λογική Boole και στην Ασαφή Λογική	39
Διάγραμμα 3.1 Διαδικασία Εκπαίδευσης και Προσαρμογή	71
Διάγραμμα 3.2 Γραμμική Συνάρτηση Μεταφοράς	72
Διάγραμμα 3.3 Δυναμική Βηματική Συνάρτηση	72
Διάγραμμα 3.4 Δυναμική Σιγμοειδής με Παραμέτρους Κλίσης $\sigma=1$ και $\sigma=3$	73
Διάγραμμα 3.5 Διπολική Σιγμοειδής	74
Διάγραμμα 4.1 Διάγραμμα Ροής της Μεθόδου Πρόβλεψης Ενός Μοντέλου ANFIS	91
Διάγραμμα 4.2 Πλεονεκτήματα ANFIS (a), (b)	116
Διάγραμμα 4.3 Μειονεκτήματα ANFIS (a), (b)	117
Διάγραμμα 5.1 ANFIS 2-4 Matlab	124
Διάγραμμα 5.2 ANFIS 3-4 Matlab	124
Διάγραμμα 5.3 ANFIS 2-4 Matlab – Αρχικές Συναρτήσεις Συμμετοχής	125
Διάγραμμα 5.4 ANFIS 3-4 Matlab – Αρχικές Συναρτήσεις Συμμετοχής	125
Διάγραμμα 5.5 ANFIS 2-4 Matlab – Τελικές Συναρτήσεις Συμμετοχής	126
Διάγραμμα 5.6 ANFIS 3-4 Matlab – Τελικές Συναρτήσεις Συμμετοχής	126
Διάγραμμα 5.7 Πραγματικές Τιμές Παραγωγής Ηλεκτρικής Ενέργειας (kwh)/ 365 Ημέρες	129
Διάγραμμα 5.8 ANFIS 2-4 Δεδομένα Εκπαίδευσης – Είσοδοι	130
Διάγραμμα 5.9 ANFIS 2-4 Δεδομένα Εκπαίδευσης – Έξοδοι	130
Διάγραμμα 5.10 ANFIS 2-4 Διασπορά Εισόδου -Εξόδου	130
Διάγραμμα 5.11 ANFIS 3-4 Δεδομένα Εκπαίδευσης – Είσοδοι	131
Διάγραμμα 5.12 ANFIS 3-4 Δεδομένα Εκπαίδευσης – Έξοδοι	131
Διάγραμμα 5.13 ANFIS 3-4 Διασπορά Εισόδου -Εξόδου	131
Διάγραμμα 5.14 ANFIS 2-4 Δεδομένα Πρόβλεψης Διασποράς εισόδων Συναρτήσει της Εξόδου	132
Διάγραμμα 5.15 ANFIS 3-4 Δεδομένα Πρόβλεψης Διασποράς εισόδων Συναρτήσει της Εξόδου	132
Διάγραμμα 5.16 ANFIS 2-4 Μορφή Κανόνων κατά τη Διαδικασία Εκπαίδευσης	133
Διάγραμμα 5.17 ANFIS 3-4 Μορφή Κανόνων κατά τη Διαδικασία Εκπαίδευσης	134
Διάγραμμα 5.18 Διάγραμμα Θέασης ANFIS 2-4	134
Διάγραμμα 5.19 Διάγραμμα Θέασης ANFIS 3-4	135
Διάγραμμα 5.20 Διάγραμμα Θέασης ANFIS 3-4	135
Διάγραμμα 5.21 Διάγραμμα Θέασης ANFIS 3-4	136
Διάγραμμα 5.22 Πραγματικές Τιμές και Πρόβλεψη ANFIS 2-4	136
Διάγραμμα 5.23 ANFIS 2-4 Σφάλμα Πρόβλεψης	137
Διάγραμμα 5.24 Πραγματικές Τιμές και Πρόβλεψη ANFIS 3-4	137
Διάγραμμα 5.25 ANFIS 3-4 Σφάλμα Πρόβλεψης	138

1^ο ΚΕΦΑΛΑΙΟ



ΕΙΣΑΓΩΓΗ

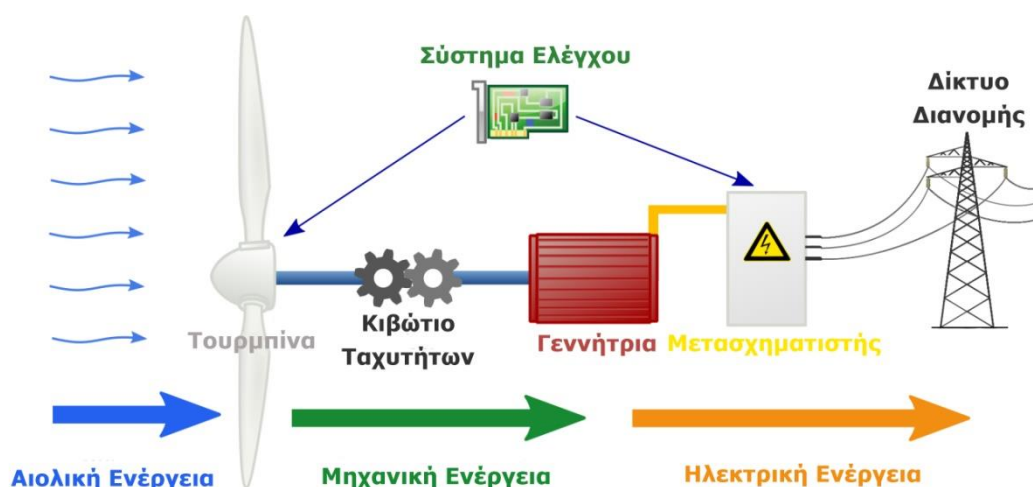
ΚΕΦΑΛΑΙΟ 1ο – ΕΙΣΑΓΩΓΗ

1.1 Αιολική Ενέργεια

1.1.1 Ορισμός

Με στόχο την μείωση των εκπομπών αερίων του θερμοκηπίου, υπεύθυνων για την υπερθέρμανση του πλανήτη, το 1997 υπογράφηκε το πρωτόκολλο του Κιότο (Kyoto Protocol) από την πλειοψηφία των κρατών ανά τον κόσμο. Μέρος της Συμφωνίας – Πλαίσιο των “Ηνωμένων Εθνών για την Κλιματική Αλλαγή” (UNFCCC), το πρωτόκολλο του Κιότο αποτελεί το πρώτο διεθνές πρωτόκολλο που επιχείρησε να περιορίσει τις εκπομπές των αερίων του θερμοκηπίου, κυρίως διοξειδίου του άνθρακα (CO₂), από τις βιομηχανικές χώρες. Κατά συνέπεια οδήγησε τα κράτη στην ανάπτυξη καθαρών πηγών ενέργειας όπως την αιολική, την ηλιακή, τη γεωθερμική και την ενέργεια από βιομάζα. Το 2012 αντικαταστάθηκε από τη Συμφωνία του Παρισιού (Paris Agreement), που επεκτείνει και ενισχύει τις προσπάθειες για την αντιμετώπιση της κλιματικής αλλαγής.

Η εκμετάλλευση της ενέργειας του ανέμου χρονολογείται από αρχαιότατων χρόνων με χαρακτηριστικά παραδείγματα τους ανεμόμυλους και τα ιστιοφόρα. Σήμερα για την αξιοποίηση της αιολικής ενέργειας για παράγωγή ηλεκτρικού ρεύματος χρησιμοποιούνται οι ανεμογεννήτριες (Α/Γ). Οι ανεμογεννήτριες είναι μηχανές οι οποίες μετατρέπουν την κινητική ενέργεια του ανέμου αρχικά σε μηχανική με την περιστροφή του άξονα της πτερωτής, και εν συνεχεία από μηχανική σε ηλεκτρική μέσω της γεννήτριας (Εικόνα 1. 1).



Εικόνα 1. 1 Διαδικασία Παραγωγής Ηλεκτρικής Ενέργειας από Αιολική

1.1.2 Βασικές Αρχές

Η συνολική αιολική ενέργεια που ρέει μέσω μιας φανταστικής επιφάνειας με εμβαδόν A (που περικλείεται από τα πτερύγια της ανεμογεννήτριας σε τετραγωνικά μέτρα m^2) κατά τη διάρκεια του χρόνου είναι:

$$E = \frac{1}{2}mv^2 = \frac{1}{2}(Avt\rho)v^2 = \frac{1}{2}At\rho v^3$$

όπου ρ είναι η πυκνότητα του αέρα (σε χιλιόγραμμα ανά κυβικό μέτρο kg/m^3), v είναι η ταχύτητα του ανέμου (σε μέτρα ανά δευτερόλεπτο m/s), Avt είναι ο όγκος του αέρα που διέρχεται από το A (ο οποίος θεωρείται κάθετος προς την κατεύθυνση του ανέμου). Επομένως, το $Avt\rho$ είναι η μάζα που διέρχεται από το " A ". $\frac{1}{2}\rho v^2$ είναι η κινητική ενέργεια του κινούμενου αέρα ανά μονάδα όγκου.

Η ισχύς είναι ενέργεια ανά μονάδα χρόνου, οπότε η ισχύς P (σε κιλοβάττ KW ή μεγαβάτ MW) της αιολικής ενέργειας μέσω μιας επιφάνειας A (π.χ. την περιοχή του ρότορα μιας ανεμογεννήτριας) είναι:

$$P = \frac{E}{t} = \frac{1}{2}A\rho v^3$$

Η αιολική ενέργεια ενός ρεύματος αέρα είναι επομένως ανάλογη με τον κύβο της ταχύτητας του ανέμου, δηλαδή η διαθέσιμη ισχύς οκταπλασιάζεται όταν η ταχύτητα του ανέμου διπλασιάζεται. Οι ανεμογεννήτριες για ηλεκτρική ισχύ στο δίκτυο, επομένως, πρέπει να είναι ιδιαίτερα αποδοτικές σε μεγαλύτερες ταχύτητες ανέμου.

1.1.3 Αποδοτικότητα

Δεν μπορεί να χρησιμοποιηθεί όλη η αιολική ενέργεια για παραγωγή ενέργειας, αν και έχουν κατασκευαστεί ορισμένες μικρές ανεμογεννήτριες, σχεδιασμένες να λειτουργούν σε χαμηλές ταχύτητες ανέμου.

Οι ανεμογεννήτριες υπακούουν στην αρχή διατήρησης της μάζας: η μάζα αέρα που εισέρχεται στην ανεμογεννήτρια θα πρέπει να είναι ίση με τη μάζα που εξέρχεται από αυτή. Σύμφωνα με το νόμο του Betz, η μέγιστη αναλογία αιολικής/κινητικής ενέργειας είναι 16/27 (59,3%).

Η μέγιστη θεωρητική παραγωγή ενέργειας είναι 16/27 φορές την κινητική ενέργεια του ανέμου που περνά από τις παραγωγικές περιοχές της γεννήτριας. Συνεπώς, αν το εμβαδόν των περιοχών αυτών είναι A και η ταχύτητα του ανέμου v , τότε η θεωρητική παραγωγή παραγωγής ενέργειας P δίνεται από τον τύπο:

$$P = \frac{16}{27} \frac{1}{2} \rho v^3 A = \frac{8}{27} \rho v^3 A \quad [1]$$

1.1.4 Πλεονεκτήματα

Η αιολική ενέργεια προσφέρει πολλά πλεονεκτήματα και έχει γίνει ευρέως αποδεκτή ως μια βιώσιμη πηγή ενέργειας (Σχήμα 1.1). Η παραγωγή αιολικής ενέργειας δεν εκπέμπει θερμοκηπιακά αέρια ή άλλες ρυπογόνες εκπομπές, καθιστώντας την, περιβαλλοντικά, πολύ φιλική. Ο άνεμος είναι ανανεώσιμος πόρος και δεν εξαντλείται με τη χρήση του. Τα αιολικά πάρκα μπορούν να τοποθετηθούν σε ευνοϊκές τοποθεσίες όπου υπάρχει ισχυρός άνεμος, μειώνοντας το κόστος μεταφοράς ενέργειας. Η ανάπτυξη, η κατασκευή και η συντήρηση των αιολικών πάρκων δημιουργούν θέσεις εργασίας σε τοπικό επίπεδο. Επίσης, η αιολική ενέργεια συμβάλλει στη μείωση της εξάρτησης από εισαγόμενα ορυκτά καύσιμα, βοηθώντας έτσι στην ενεργειακή ασφάλεια, ενισχύει την οικονομία δημιουργώντας οικονομική δραστηριότητα.



Σχήμα 1.1 Πλεονεκτήματα Αιολικής Ενέργειας

Παρόλα αυτά, η αιολική ενέργεια έχει και μειονεκτήματα όπως η επίδραση των αιολικών πάρκων στο περιβάλλον, το κόστος εγκατάστασης και μεταφοράς της ενέργειας, η ηχορύπανση, η δέσμευση έκτασης γης κλπ. Κύριο όμως μειονέκτημα αποτελεί **η εξάρτηση από τον άνεμο καθώς η αστάθεια ανέμου οδηγεί στη μη ελεγχόμενη παραγωγή της**. Κατά συνέπεια μπορεί να απαιτηθεί αποθήκευση ενέργειας ή εναλλακτικές πηγές για να καλυφθούν οι ενεργειακές ανάγκες. Τα περισσότερα από αυτά τα μειονεκτήματα είναι

αντικείμενο συνεχούς έρευνας και ανάπτυξης, καθώς η τεχνολογία της αιολικής ενέργειας εξελίσσεται συνεχώς για τη μείωση των περιβαλλοντικών και κοινωνικών επιπτώσεων.

Συνοψίζοντας, τα πλεονεκτήματά της αιολικής ενέργειας υπερτερούν καθιστώντας της ως σημαντική πηγή ενέργειας για το μέλλον και για την καταπολέμηση της κλιματικής αλλαγής.

1.1.5 Έκθεση Ευρωπαϊκής Ένωσης Αιολικής Ενέργειας (EWEA) 2022

Η Ευρωπαϊκή Ένωση αποτελεί ίσως τον πιο ένθερμο υποστηρικτή της χρήσης ανανεώσιμων πηγών ενέργειας και κυρίως της αιολικής. Σύμφωνα με τα στοιχεία της **Ευρωπαϊκής Ένωσης Αιολικής Ενέργειας (European Wind Energy Association – EWEA)** μέχρι το τέλος του 2022, η συνολική εγκατεστημένη αιολική ισχύς στην Ευρώπη ήταν 255 GW: εκ των οποίων 225 GW στην ξηρά και 30GW υπεράκτια, καλύπτοντας το 17% της ζήτησης ηλεκτρικής ενέργειας το 2022 σε ΕΕ-27¹ και Ηνωμένο Βασίλειο, από 13% πριν από πέντε χρόνια. Η ΕΕ-27 έχει εγκατεστημένη ισχύ αιολικών πάρκων 204 GW με 188 GW στην ξηρά και 16 GW στη θάλασσα.

Σύμφωνα με την έκθεση, οι έξι κορυφαίες χώρες εγκατάστασης αιολικής ισχύος στην Ευρώπη το 2022, ήταν η Γερμανία (26%), η Ισπανία (12%), το Ηνωμένο Βασίλειο (11%), η Γαλλία (8%), η Σουηδία (6%) και η Τουρκία (5%), έχοντας έτσι τη μεγαλύτερη συνεισφορά στο συνολικό δυναμικό της Ευρώπης καλύπτοντας τα $\frac{2}{3}$ της συνολικής εγκατεστημένης ισχύος. Η Δανία και η Ιρλανδία είχαν το υψηλότερο ποσοστό αιολικής ενέργειας στο σύνολο της ηλεκτρικής ενέργειας τους, με ποσοστό 55% και 34% αντίστοιχα, ενώ σε άλλες πέντε χώρες, η αιολική ενέργεια κάλυπτε πάνω από το 20% της ηλεκτρικής ζήτησης: Ηνωμένο Βασίλειο (28%), Γερμανία (26%), Πορτογαλία (26%), Ισπανία (25%) και Σουηδία (25%) [2].

1.2 Η Σημασία της Πρόβλεψης

Όπως προαναφέρθηκε, πέρα από τα προφανή περιβαλλοντικά οφέλη που προκύπτουν από την εγκατάσταση και λειτουργία των μονάδων παραγωγής αιολικής ενέργειας, το βασικό μειονέκτημά τους είναι η μη ελεγχόμενη παραγωγή τους. Αυτό οφείλεται στην ιδιαίτερα περιορισμένη προβλεπτικότητα

¹ ΕΕ-27: 27 χώρες της Ε.Ε. μετά την έξοδο του Ηνωμένου Βασιλείου

και υψηλή μεταβλητότητα που παρουσιάζει η πρωτογενής πηγή ενέργειας (π.χ. άνεμος, ήλιος), σε αντίθεση με τους συμβατικούς σταθμούς παραγωγής (π.χ. λιγνιτικούς, φυσικού αερίου, πετρελαϊκούς, κ.α.), η παραγωγή των οποίων είναι σε μεγάλο βαθμό προγραμματιζόμενη και ελεγχόμενη από τον Διαχειριστή του Συστήματος. **Συνεπώς, η ανάπτυξη και χρήση προηγμένων εργαλείων πρόβλεψης της παραγόμενης ενέργειας από ΑΠΕ κρίνεται πλέον απαραίτητη για τη διασφάλιση της ασφαλούς και αποδοτικής λειτουργίας των σύγχρονων συστημάτων ηλεκτρικής ενέργειας.** Το παρακάτω Σχήμα 1.2 απεικονίζει επιγραμματικά τα κύρια οφέλη πρόβλεψης της αιολικής ενέργειας.



Σχήμα 1.2 Οφέλη Πρόβλεψης Αιολικής Ενέργειας

Η πρόβλεψη της αιολικής ενέργειας αποτελεί θέμα ζωτικής σημασίας για την αειφόρο ανάπτυξη του ενεργειακού τομέα και την επίτευξη των στόχων της εκάστοτε χώρας στον τομέα της ανανεώσιμης ενέργειας και του περιβάλλοντος, συμβάλλοντας παράλληλα στην ενεργειακή της ανεξαρτησία.

1.3 Βραχυπρόθεσμος Χρονικός Ορίζοντας Πρόβλεψης 1 Ημέρας

Η αγορά ηλεκτρικής ενέργειας λειτουργεί με βάση διάφορους χρονικούς ορίζοντες, ανάλογα με την προβλεπόμενη διάρκεια των αποφάσεων και των προγραμματισμένων ενεργειακών ενεργειών. Κάθε χρονικός ορίζοντας έχει

συγκεκριμένες εφαρμογές που στοχεύουν στη βέλτιστη λειτουργία του συστήματος παραγωγής και διανομής ηλεκτρικής ενέργειας.

1.3.1 Χρονικοί Ορίζοντες

Στις μεθόδους πρόβλεψης, εκτός του τρόπου προσέγγισης και ανάλυσης, διαφοροποιούνται και οι χρονικές κλίμακες ανάλογα με τον στόχο κάθε μεθόδου. Βάσει λοιπόν του χρονικού ορίζοντα, η μεθοδολογία πρόβλεψης του ανέμου διαιρείται σε τέσσερις κατηγορίες. **Οι προβλέψεις Υπέρ - Βραχυπρόθεσμου (Ultra - Short - Term ahead) και Βραχυπρόθεσμου (Short - Term ahead) ορίζοντα καλύπτουν πολύ μικρά χρονικά διαστήματα, οι Μεσοπρόθεσμες προβλέψεις (Medium - Term ahead) αντιμετωπίζουν επικείμενες αλλαγές σε ώρες ή ημέρες, ενώ οι μακροπρόθεσμες προβλέψεις (Long - Term ahead) αναλαμβάνουν την πρόβλεψη για εβδομάδες, μήνες, χρόνια ή ακόμα και περισσότερο για στρατηγικούς σκοπούς.**

Στον παρακάτω Πίνακα 1.1 [3], ταξινόμησης της πρόβλεψης του ανέμου βάσει του χρονικού ορίζοντα, παρουσιάζονται και οι εφαρμογές στην αγορά ηλεκτρικής ενέργειας, οι οποίες διαφέρουν σημαντικά μεταξύ τους.

Πίνακας 1.1 Χρονικοί Ορίζοντες Πρόβλεψης και Εφαρμογές

Χρονικός Ορίζοντας	Εύρος	Εφαρμογές στην αγορά ηλεκτρικής ενέργειας
Υπέρ - Βραχυπρόθεσμος Ultra - Short - Term ahead	λίγα λεπτά έως 1 ώρα	<ul style="list-style-type: none"> • Εκκαθάριση Αγοράς Ηλεκτρικής Ενέργειας • Λειτουργίες δικτύου σε πραγματικό χρόνο • Κανονιστικές δράσεις
Βραχυπρόθεσμος Short - Term ahead	1 ώρα έως μερικές ώρες	<ul style="list-style-type: none"> • Σχεδιασμός Κατανομής Οικονομικού Φορτίου • Λογικές Αποφάσεις για το Φορτίο • Λειτουργική Ασφάλεια στην Αγορά Ηλεκτρικής Ενέργειας
Μεσοπρόθεσμος Medium - Term ahead	μερικές ώρες έως 1 εβδομάδα	<ul style="list-style-type: none"> • Αποφάσεις Δέσμευσης Μονάδων • Αποφάσεις Αποθεματικού Εφεδρείας • Αποφάσεις Ενεργοποίησης/Απενεργοποίησης Γεννητρών
Μακροπρόθεσμος Long - Term ahead	1 εβδομάδα έως 1 έτος ή και περισσότερο	<ul style="list-style-type: none"> • Προγραμματισμός Συντήρησης • Διαχείριση Λειτουργίας • Βέλτιστο Λειτουργικό Κόστος • Μελέτη Δυνατότητας για τον Σχεδιασμό Αιολικού Πάρκου

Σύμφωνα με την τρέχουσα κατάσταση στις μεθόδους πρόβλεψης της ταχύτητας του ανέμου, συχνά υπάρχει η πιθανότητα της πρόβλεψης με σημαντικά ανώτερα σφάλματα. Το επίπεδο σφάλματος στις προβλέψεις της ταχύτητας του ανέμου είναι μεγαλύτερο από ότι στις προβλέψεις του φορτίου.

Επιπλέον, η πρόβλεψη της ταχύτητας του ανέμου είναι λιγότερο ακριβής σε μεγάλα χρονικά διαστήματα σε σύγκριση με τις προβλέψεις για σύντομα χρονικά διαστήματα. Αξίζει να σημειωθεί ότι οι προβλέψεις της ταχύτητας του ανέμου μπορεί να διατηρούν αξία ακόμη και αν δεν είναι πολύ ακριβείς. Επιπλέον, τα σφάλματα στις προβλέψεις επηρεάζουν λιγότερο τα απομονωμένα αιολικά πάρκα σε σύγκριση με τα ατομικά πάρκα λόγω της εξομάλυνσης που προκαλείται από τη γεωγραφική διάχυση [4].

Στην παρούσα εργασία θα επικεντρωθούμε στον Βραχυπρόθεσμο Χρονικό Ορίζοντα Πρόβλεψης 1 Ημέρας (Short – Term One Day ahead).

1.3.2 Στάδια Βραχυπρόθεσμης Πρόβλεψης (Short – Term One Day ahead)

Η διαδικασία πρόβλεψης της αιολικής ενέργειας για την επόμενη μέρα αποτελείται από διάφορα στάδια. Αρχικά **συλλέγονται όλα τα σχετικά δεδομένα** με την αιολική ενέργεια όπως η ταχύτητα και η κατεύθυνση του ανέμου, οι μετεωρολογικές συνθήκες, παράμετροι όπως η θερμοκρασία και η υγρασία και τα χαρακτηριστικά του αιολικού πάρκου. Κατόπιν γίνεται **επεξεργασία των δεδομένων, έλεγχος και διόρθωση** πιθανών σφαλμάτων ώστε τα δεδομένα να καταχωρηθούν σωστά στο προγνωστικό μοντέλο. Στη συνέχεια **επιλέγεται το κατάλληλο μοντέλο πρόβλεψης**, το οποίο εκπαιδεύεται χρησιμοποιώντας τα παραπάνω επεξεργασμένα δεδομένα. Η επιλογή του κατάλληλου μοντέλου πρόβλεψης γίνεται ανάλογα με τον βαθμό πολυπλοκότητας του προβλήματος και τη διαθεσιμότητα των δεδομένων, ενώ ταυτόχρονα **εκτελείτε επαλήθευση του μοντέλου** ως προς την ακρίβεια και την αξιοπιστία του, χρησιμοποιώντας δεδομένα παρατήρησης. Τελικά στάδια αποτελούν η **εξαγωγή της τελικής πρόβλεψης** και φυσικά **η αξιολόγηση της απόδοσης** βάσει της ακρίβειας της πρόβλεψης καθώς γίνεται σύγκριση της πραγματικής παραγωγής με την προβλεπόμενη. Πρέπει να σημειωθεί ότι η ακρίβεια των προβλέψεων εξαρτάται σε μεγάλο βαθμό από την ποιότητα των δεδομένων, την επιλογή του μοντέλου και την ενημέρωση των παραμέτρων του μοντέλου.

1.3.3 Πλεονεκτήματα Βραχυπρόθεσμης Πρόβλεψης (Short – Term One Day ahead)

Η βραχυπρόθεσμη πρόβλεψη αιολικής ενέργειας εμπεριέχει μεγαλύτερη ακρίβεια σε σύγκριση με τις προβλέψεις για μεγάλα χρονικά διαστήματα ενώ παράλληλα προσφέρει πολλά πλεονεκτήματα.

Η ακριβής πρόβλεψη της παραγωγής ενέργειας από αιολικά πάρκα μέχρι και δύο ημέρες πριν αποτελεί σημαντική συνεισφορά για την αξιόπιστη ενσωμάτωση μεγάλης κλίμακας αιολικής ενέργειας. Καθώς η ενσωμάτωση αυξάνεται, οι απαιτήσεις για προβλέψεις της παραγωγής αναπτύσσονται ανάλογα με τον τελικό χρήστη και το πλαίσιο. Η αιολική ενέργεια ανήκει στις ΑΠΕ με το χαμηλότερο κόστος παραγωγής ηλεκτρικής ενέργειας και τη μεγαλύτερη διαθέσιμη πηγή. Οι τεχνολογίες αιολικής ενέργειας είναι πλέον αρκετά ώριμες για να αποτελούν σημαντική συνεισφορά. Η απαίτηση για ασφαλή και αξιόπιστη λειτουργία του συστήματος ηλεκτρικής ενέργειας λειτουργεί ως περιοριστικός παράγοντας για τη διείσδυση του ανέμου.

Η εμπειρία χωρών με μεγάλη ενσωμάτωση έχει δείξει ότι για την διαχείριση παραγωγής αιολικής ενέργειας, απαιτούνται προηγμένα εργαλεία τα οποία βοηθούν τους τελικούς χρήστες, όπως είναι οι επιχειρήσεις κοινής ωφέλειας, οι ανεξάρτητοι παραγωγοί ηλεκτρικής ενέργειας, ή οι διαχειριστές συστημάτων μεταφοράς. Επίσης, η διαθεσιμότητα ακριβών προβλέψεων για την παραγωγή αιολικής ενέργειας μερικές ώρες στο μέλλον επιτρέπει τη μείωση των προστίμων σε μία στοχευμένη αγορά που προέρχονται από υπερεκτιμήσεις ή υποεκτιμήσεις της παραγωγής.

Σήμερα, έχουν αναπτυχθεί αρκετά εργαλεία για την πρόβλεψη αιολικής ενέργειας που επικεντρώνονται σε χερσαίες εφαρμογές και βασίζονται είτε σε φυσική (λεπτομερής αναπαράσταση εδάφους, τραχύτητα κ.λπ.) είτε σε στατιστική μοντελοποίηση (δηλαδή μοντέλα "μαύρου" ή "γκρι κουτιού" που βασίζονται μόνο σε δεδομένα). Η αρχιτεκτονική του συστήματος πρόβλεψης είναι αρθρωτή ώστε να επιτρέπεται η παράλληλη λειτουργία εναλλακτικών μοντέλων και συνδυασμός των προβλέψεών τους για μια υψηλή αξιοπιστία και μια βέλτιστη ολική ακρίβεια [5].

Στον παρακάτω Πίνακα 1.2 αποτυπώνονται επιγραμματικά, τα πλεονεκτήματα της Βραχυπρόθεσμης Πρόβλεψης.

Πίνακας 1.2 Πλεονεκτήματα Βραχυπρόθεσμης Πρόβλεψης



Συνοπτικά, η βραχυπρόθεσμη πρόβλεψη αιολικής ενέργειας διαδραματίζει κρίσιμο ρόλο στην επιτυχή ενσωμάτωση της αιολικής ενέργειας στο ευρύτερο ενεργειακό τοπίο.

1.4 Ανασκόπηση Μοντέλων Πρόβλεψης

Για να αντιμετωπιστεί η πρόκληση της αστάθειας και της ακρίβειας, έχουν αναπτυχθεί διάφορες τεχνικές πρόβλεψης της ισχύος και της κατεύθυνσης του ανέμου. Αυτές οι τεχνικές διαχωρίζονται βάσει προσέγγισης σε πέντε βασικές κατηγορίες:

1. Προσέγγιση με την Μέθοδο Παραμένουσας Πρόβλεψης (Persistent Method)
2. Φυσική Προσέγγιση (Physical Approach)
3. Στατιστικές Προσεγγίσεις (Statistical Approaches)
4. Προσέγγιση μέσω Νέων Τεχνικών (New Techniques Approach) και
5. Προσέγγιση με Υβριδικές Δομές (Hybrid Structures Approach)

1.4.1 Προσέγγιση με την Μέθοδο Παραμένουσας Πρόβλεψης (Persistent Method)

Η μέθοδος Παραμένουσας Πρόβλεψης (Persistent Method) υποθέτει ότι οι συνθήκες τη στιγμή της πρόβλεψης δεν θα αλλάξουν, ότι δηλαδή η ταχύτητα του ανέμου τη χρονική στιγμή « $t + \Delta t$ » θα είναι η ίδια όπως ήταν τη στιγμή « t ».

Η μέθοδος αυτή είναι πιο ακριβής από τις περισσότερες φυσικές και στατιστικές μεθόδους για πολύ βραχυπρόθεσμες έως βραχυπρόθεσμες προβλέψεις και **αποτελεί προσέγγιση συγκριτικής αξιολόγησης (Benchmarking Approach)**. Ως εκ τούτου, οποιαδήποτε μέθοδος πρόβλεψης που αναπτύσσεται θα πρέπει πρώτα να δοκιμαστεί σε σχέση με την κλασική Μέθοδο Παραμένουσας Πρόβλεψης για να ελεγχθεί πόσο μπορεί να βελτιωθεί σε σχέση με αυτήν την τεχνική.

1.4.2 Φυσική Προσέγγιση (Physical Approach)

Η **Αριθμητική Πρόβλεψη Καιρού (NWP – Numeric Weather Predictors)** αποτελεί μία **Φυσική Προσέγγιση** κατά την οποία συστήματα και μοντέλα πρόβλεψης που χρησιμοποιούνται στη μετεωρολογία όπως: το Παγκόσμιο Αριθμητικό Μοντέλο Πρόβλεψης Καιρού (GFS – Global Forecasting System), το Μοντέλο Προσομοίωσης της ατμοσφαιρικής κυκλοφορίας σε Μεσοκλιματική Κλίμακα Πέμπτης Γενιάς (MM5 – Fifth-Generation Mesoscale Model), το Μοντέλο Prediktor, το Μοντέλο Υψηλής Ανάλυσης Περιορισμένης – Περιοχής (HIRLAM – High – Resolution Limited – Area Model) κ.α., προσομοιώνουν μια σειρά μετεωρολογικών δεδομένων, συμπεριλαμβανομένης της ταχύτητας και κατεύθυνσης του ανέμου, της πίεσης, της θερμοκρασίας, της υγρασίας, και πληροφοριών σχετικά με την τοπογραφία (τραχύτητα επιφάνειας, πιθανά εμπόδια). Η Αριθμητική Πρόβλεψη Καιρού αποδίδεται σε υπερυπολογιστές καθώς χρειάζεται πολλούς υπολογισμούς, εκτελείται συνήθως 1 ή 2 φορές την ημέρα λόγω της δυσκολίας απόκτησης πληροφοριών σε σύντομο χρονικό διάστημα και του σχετικού υψηλού κόστους. Αυτή η προσέγγιση **είναι ιδιαίτερα χρήσιμη για μακροπρόθεσμες προβλέψεις και αρκετά ακριβής προβλέψεις όταν οι καιρικές συνθήκες είναι σταθερές, αλλά μπορεί να απαιτεί πολλούς υπολογισμούς και μεγάλο όγκο δεδομένων**.

1.4.3 Στατιστικές Προσεγγίσεις (Statistical Approaches)

Η **Στατιστική Προσέγγιση** βασίζεται στην εκπαίδευση με δεδομένα μετρήσεων και χρησιμοποιεί τη διαφορά μεταξύ της προβλεπόμενης και της πραγματικής ταχύτητας ανέμου στο άμεσο παρελθόν για να συντονίσει τις παραμέτρους του μοντέλου. **Είναι εύκολο να μοντελοποιηθεί, χαμηλού κόστους και παρέχει έγκαιρες προβλέψεις. Βασίζεται σε μοτίβα, όπου αν αυτά συναντώνται με ιστορικά μοτίβα, τότε τα σφάλματα**

ελαχιστοποιούνται. Η προσέγγιση αυτή διαιρείται σε: α) σε μοντέλα που βασίζονται σε Χρονοσειρές (Timeseries Models) και β) μεθόδους βασισμένες σε Νευρωνικά Δίκτυα (NN – Neural Networks)

α) Χρονοσειρές (Timeseries Models)

Παραδείγματα στατιστικών μοντέλων με **Χρονοσειρές** αποτελούν: το Αυτοπαγωγικό μοντέλο με Εξωγενή Είσοδο ARX (AutoRegressive with eXogenous input) το οποίο χρησιμοποιείται για πρόβλεψη χρονοσειρών λαμβάνοντας υπόψη και εξωτερικές εισόδους, το Αυτοπαγωγικό Μεταβατικό Μέσο ARMA (AutoRegressive Moving Average) κατάλληλο για σταθερές χρονοσειρές, συνδυάζοντας αυτοπαγωγικούς και μεταβατικούς όρους, το Αυτοπαγωγικό Ολοκληρωμένο Μεταβατικό Μέσο ARIMA (AutoRegressive Integrated Moving Average) το οποίο χρησιμοποιείται για σταθεροποίηση μη σταθερών χρονοσειρών με διαφοροποίηση, στη συνέχεια χρησιμοποιεί αυτοπαγωγικούς και μεταβατικούς όρους, τα μοντέλα Grey Predictors κατάλληλα για συστήματα με περιορισμένες πληροφορίες και αβεβαιότητα, τα μοντέλα Γραμμικών Προβλέψεων Linear Predictions τα οποία χρησιμοποιούν γραμμικές σχέσεις μεταξύ των μεταβλητών για προβλέψεις και το μοντέλο Exponential Smoothing το οποίο ενημερώνει τις προβλέψεις με βάση τα πιο πρόσφατα δεδομένα, με μεγαλύτερη βαρύτητα στα πιο πρόσφατα παρατηρούμενα.

Τα μοντέλα Auto – Regressive Moving Average (ARMA) είναι ο πιο δημοφιλής τύπος. Οι χρονοσειρές λόγω της ακρίβειάς τους, ενδείκνυνται για βραχυπρόθεσμες προβλέψεις. Επιπροσθέτως, μερικά πολύ καλά μοντέλα χρονοσειρών αντικαθιστούν τις δομές των Νευρωνικών Δικτύων.

β) Νευρωνικά Δίκτυα (NN – Neural Networks)

Τα **Νευρωνικά Δίκτυα** εκπαιδεύονται χρησιμοποιώντας προηγούμενα δεδομένα που λαμβάνονται σε μεγάλο χρονικό διάστημα για να μάθουν τη σχέση μεταξύ δεδομένων εισόδου και ταχυτήτων ανέμου εξόδου. Τα Νευρωνικά Δίκτυα έχουν ένα επίπεδο εισόδου όπου τροφοδοτούνται ιστορικά δεδομένα για εκμάθηση, κρυφά επίπεδα και ένα επίπεδο εξόδου που παρέχει αποτελέσματα πρόβλεψης. Τα μοντέλα Νευρωνικών Δικτύων μπορεί να είναι: τροφοδοσίας FNN (Feedforward Neural Network), επαναλαμβανόμενα RNN (Recurrent Neural

Network), πολυεπίπεδα MLP (Multilayer Perceptron), συνάρτησης ακτινικής βάσης RBF (Radial Basis Function Network) NNs, προσαρμοστικού γραμμικού νευρώνα Adaline (Adaptive Linear Neuron), κ.λπ.

Τα νευρωνικά δίκτυα είναι ακριβή για βραχυπρόθεσμες προβλέψεις, ενώ οι υβριδικές δομές τους είναι χρήσιμες για μεσοπρόθεσμες έως μακροπρόθεσμες προβλέψεις. Όσο ο αριθμός των διανυσμάτων εκπαίδευσης αυξάνεται για το δεδομένο μοντέλο νευρωνικού δικτύου, τόσο βελτιώνεται η απόδοσή του. Συνήθως, ξεπερνούν τα μοντέλα χρονοσειρών για όλες σχεδόν τις χρονικές κλίμακες.

1.4.4 Προσέγγιση μέσω Νέων Τεχνικών (New Techniques Approach)

Νέες Τεχνικές αποτελούν:

1. η **Χωρική Συσχέτιση (Spatial Correlation)** η οποία αξιοποιεί τη σχέση μεταξύ ταχυτήτων ανέμου σε διάφορες γεωγραφικές τοποθεσίες και είναι κατάλληλη για βραχυπρόθεσμες προβλέψεις,
2. η **Ασαφής Λογική (Fuzzy Logic)** η οποία λαμβάνει υπόψη την αβεβαιότητα στις μετρήσεις των ανέμων για πιο ακριβείς προβλέψεις,
3. ο **Μετασχηματισμός Κυματιδίων (Wavelet Transform)** ο οποίος αποτελείτε από μαθηματικούς υπολογισμούς για τον αναλυτικό διαχωρισμό σημάτων σε συνιστώσες κυμάτων με διαφορετικές κλίμακες,
4. η τεχνική **Συνόλου Προβλέψεων (Ensemble Predictions)** η οποία βελτιώνει την ακρίβεια συγχωνεύοντας πολλά μοντέλα πρόβλεψης και
5. η τεχνική **Εκπαίδευσης βασισμένη στην Εντροπία (Entropy based training)** για βελτίωση της απόδοσης.

1.4.5 Προσέγγιση με Υβριδικές Δομές (Hybrid Structures Approach)

Η προσέγγιση με **Υβριδικές Δομές** συνδυάζει δύο ή περισσότερες από τις προαναφερθείσες προσεγγίσεις όπως π.χ. μίξη φυσικών και στατιστικών προσεγγίσεων ή ο συνδυασμός βραχυπρόθεσμων και μεσοπρόθεσμων μοντέλων, με σκοπό να βελτιώσει την ακρίβεια και την αξιοπιστία των προβλέψεων της ισχύος και της ταχύτητας του ανέμου. Παραθέτουμε κάποια παραδείγματα Υβριδικών Δομών:

1. **Τεχνητά Νευρωνικά Δίκτυα (ANN) + Ασαφής Λογική (Fuzzy Logic) = ANFIS**
2. Αριθμητική Πρόβλεψη Καιρού (NWP)+ Νευρωνικά Δίκτυα (NN)
3. Χωρική Συσχέτιση (Spatial Correlation) + Νευρωνικά Δίκτυα (NN)
4. Αριθμητική Πρόβλεψη Καιρού (NWP) + Χρονοσειρές (Timeseries Models)

Η υβριδική δομή ANFIS αποδεικνύεται εξαιρετικά αποτελεσματική για βραχυπρόθεσμες προβλέψεις, ενώ ο συνδυασμός NWP + NN εξασφαλίζει υψηλή ακρίβεια σε μεσοπρόθεσμες και μακροπρόθεσμες προβλέψεις [6].

Πέραν των προαναφερθέντων τεχνικών πρόβλεψης, υπάρχουν επίσης βασικές προσεγγίσεις όπως η αξιοποίηση της καμπύλης ισχύος ανεμογεννήτριας ανά μονάδα ξεχωριστά και η συγχώνευση των αποτελεσμάτων, καθώς και η μέθοδος σταθερότητας που υποθέτει σταθερότητα στην ταχύτητα και την κατεύθυνση του ανέμου για σύντομα χρονικά διαστήματα. Ωστόσο, αυτές οι απλούστερες μέθοδοι μπορεί να μην παρέχουν τα πλέον ακριβή αποτελέσματα σε σύγκριση με πιο προηγμένες τεχνικές πρόβλεψης.

Συνολικά, η πρόβλεψη της ισχύος και της ταχύτητας του ανέμου αποτελεί ένα πολύπλοκο και απαιτητικό πρόβλημα. Ωστόσο, η εξέλιξη προηγμένων τεχνικών πρόβλεψης έχει διευκολύνει την αποτελεσματική ενσωμάτωση της αιολικής ενέργειας στο ηλεκτρικό δίκτυο.


1.5 Μέθοδος ANFIS για Πρόβλεψη

Η Μέθοδος ANFIS (Adaptive Neuro - Fuzzy Inference System) αντιπροσωπεύει το Προσαρμοστικό Σύστημα Νευρο - ασαφούς Συμπερασμού και πρόκειται για ένα υβριδικό μοντέλο που συνδυάζει δύο ευφυή συστήματα: την μάθηση των Τεχνητών Νευρωνικών Δικτύων (ANN) με τις ικανότητες συλλογισμού της Ασαφούς Λογικής (Fuzzy Logic) και πιο συγκεκριμένα τα Συστήματα Ασαφών Συμπερασμάτων (FISs Fuzzy Inference Systems).

Τα FIS βασίζονται στη ασαφή λογική (ένα συνεχές εύρος τιμών αλήθειας από το 0 έως το 1), **στους ασαφείς κανόνες IF - THEN** και στη ασαφή συλλογιστική (που μπορεί να παρομοιαστεί με τον ανθρώπινο συλλογισμό μέσω γλωσσικών μεταβλητών όπως μικρές, μεσαίες, μεγάλες). Το τμήμα IF των κανόνων ονομάζεται προγενέστερο: ενώ το τμήμα THEN αναφέρεται ως το επακόλουθο ή το συμπέρασμα. Τα συστήματα ANFIS εκμεταλλεύονται την ικανότητα αυτομάθησης των νευρωνικών δικτύων για να προσαρμόσουν

αυτόματα τις λειτουργίες μέλους του ασαφούς συστήματος σε μια προσαρμοστική μορφή.

1.5.1 Επίπεδα Αρχιτεκτονικής ANFIS



Διάγραμμα 1.1 Αρχιτεκτονική ANFIS

Στο παραπάνω διάγραμμα βλέπουμε την **Αρχιτεκτονική ANFIS**, η οποία αποτελείται από πέντε επίπεδα και είναι λειτουργικά **ισοδύναμη με ένα Ασαφές Σύστημα Συμπερασμάτων τύπου Sugeno**.

- **Επίπεδο 1: Επίπεδο Ασάφειας (Fuzzification).** Αυτό το επίπεδο μετατρέπει τα στοιχεία της εισόδου σε ασαφή σύνολα. Παρουσιάζονται στο δίκτυο τα δεδομένα που αντιπροσωπεύουν το σύστημα που πρόκειται να μοντελοποιηθεί. Στη συνέχεια το προσαρμοστικό δίκτυο ταξινομεί τα δεδομένα σε ομάδες που ονομάζονται ασαφείς χώροι αναζητώντας μοτίβα μέσα σε αυτό. Το ANFIS χρησιμοποιεί συναρτήσεις ασαφούς μέλους (MFs) για να δημιουργήσει τους χώρους εισόδου. Αυτοί οι χώροι εισόδου έχουν επικαλυπτόμενα MF για να επιτρέπουν την ταυτόχρονη ενεργοποίηση πολλών περιοχών από ένα μόνο σημείο. Οι εισοδοί συγκρίνονται με τα MF στα προηγούμενα των κανόνων του μοντέλου ANFIS για να καθοριστεί σε ποιο βαθμό οι εισοδοί ανήκουν στα ασαφή σύνολα. Αυτή η διαδικασία, που ονομάζεται επίσης **fuzzification**, πραγματοποιείται στο επίπεδο 1. Σε αυτή τη διαδικασία, ο βαθμός στον οποίο κάθε είσοδος ανήκει σε έναν ασαφή χώρο εκχωρείται μια τιμή μεταξύ 0 και 1.
- **Επίπεδο 2: Επίπεδο Κανόνων (Rule Layer).** Σε αυτό το επίπεδο, εφαρμόζονται οι ασαφείς κανόνες IF – THEN στα ασαφή σύνολα που προήχθησαν στο προηγούμενο στάδιο. Κάθε κόμβος είναι σταθερός και αντιπροσωπεύεται από έναν κανόνα. Κάθε κόμβος αυτού του επιπέδου πολλαπλασιάζει τα εισερχόμενα σήματα που δείχνουν τους βαθμούς στους οποίους οι εισοδοί ικανοποιούν τις συναρτήσεις μέλους. Το γινόμενο των

σημάτων εισόδου σε κάθε κόμβο σε αυτό το επίπεδο αντιπροσωπεύει τον βαθμό ενεργοποίησης ενός κανόνα.

- **Επίπεδο 3: Επίπεδο Κανονικοποίησης (Normalization).** Αυτό το επίπεδο κανονικοποιεί τους βαθμούς ενεργοποίησης των κανόνων. Κάθε κόμβος υπολογίζει την αναλογία του βαθμού ενεργοποίησης του $i^{\text{ου}}$ κανόνα προς το άθροισμα των βαθμών ενεργοποίησης όλων των κανόνων. Η έξοδος κάθε κόμβου είναι επομένως ένας κανονικοποιημένος βαθμός ενεργοποίησης κάθε κανόνα.
- **Επίπεδο 4: Επίπεδο Αποασαφοποίησης (Defuzzification).** Σε αυτό το επίπεδο συγκεντρώνονται οι έξοδοι των κανόνων και παράγεται μια σαφής έξοδος. Κάθε κόμβος υπολογίζει τη σταθμισμένη συνακόλουθη τιμή κάθε κανόνα που αντιπροσωπεύει τη συμβολή του στη συνολική έξοδο.
- **Επίπεδο 5: Επίπεδο Προσαρμογής (Adaptive Layer).** Το τελευταίο επίπεδο είναι ένα επίπεδο άθροισης που έχει έναν μόνο κόμβο που υπολογίζει το άθροισμα όλων των εξόδων του Επιπέδου 4.

Αυτά τα στάδια συνεργούν για να δημιουργήσουν ένα υβριδικό μοντέλο που ενσωματώνει τις δυνατότητες μάθησης των νευρωνικών δικτύων με την ικανότητα συλλογισμού της ασαφούς λογικής. **Αυτό έχει ως αποτέλεσμα το προγνωστικό μοντέλο ANFIS να είναι πιο ακριβές και αξιόπιστο [7].**

1.5.2 Εφαρμογές ANFIS

Το προγνωστικό μοντέλο **ANFIS** περιλαμβάνει μια ευρεία γκάμα εφαρμογών εξαιτίας της ικανότητάς του να αντιμετωπίζει πολύπλοκες, μη – γραμμικές σχέσεις και αβεβαιότητα. Ορισμένες από τις κύριες εφαρμογές του ANFIS περιλαμβάνουν τα παρακάτω:

- **Μοντελοποίηση Δυναμικών Συστημάτων** με πολύπλοκη, μη γραμμική συμπεριφορά (μηχανική, οικονομικά, βιολογία)
- **Πρόβλεψη Χρονοσειρών** (πρόβλεψη χρηματιστηρίου, καιρού, εφαρμογές μηχανικής)
- **Συστήματα Ελέγχου** (σχεδιασμός και εφαρμογή συστημάτων ελέγχου)
- **Αναγνώριση Προτύπων** (αναγνώριση εικόνας, ομιλίας)
- **Χρηματοοικονομική Πρόβλεψη** (πρόβλεψη τιμών μετοχών, οικονομικών δεικτών)

- **Ιατρική Διάγνωση και Υγειονομική Περίθαλψη** (διάγνωση και παρακολούθηση ασθενών, ανάλυση ιατρικής εικόνας)
- **Ρομποτική και Αυτοματισμός** (έλεγχος κίνησης, σχεδιασμός διαδρομής, αποφυγή εμποδίων)
- **Βελτιστοποίηση Διαδικασιών** (βελτιστοποίηση παραμέτρων για βελτιωμένη απόδοση, ποιοτικό έλεγχο και χρήση πόρων)
- **Περιβαλλοντική Μοντελοποίηση** (μοντελοποίηση και πρόβλεψη φαινομένων όπως η ποιότητα του αέρα, του νερού κλπ)
- **Οικονομική Μοντελοποίηση και Πρόβλεψη** (μοντελοποίηση συμπεριφοράς καταναλωτών, πρόβλεψη ζήτησης, ανάλυση οικονομικών τάσεων)
- **Συστήματα Ισχύος και Διαχείριση Ενέργειας** (βελτιστοποίηση της παραγωγής, διανομής και κατανάλωσης ηλεκτρικής ενέργειας)
- **Πρόβλεψη και βελτιστοποίηση ροής κυκλοφορίας** (πρόβλεψη μοτίβων ροής κυκλοφορίας, βελτιστοποίηση πλάνου διαχείρισης κυκλοφορίας) κ.α.

Οι παραπάνω αποτελούν μόνο μερικές από το πλήθος πιθανών εφαρμογών του ANFIS. Η αποτελεσματικότητα ενός μοντέλου ANFIS για μια συγκεκριμένη χρήση εξαρτάται από παράγοντες όπως η διαθεσιμότητα υψηλής ποιότητας δεδομένων εκπαίδευσης, η πολυπλοκότητα των σχέσεων που αντιμετωπίζονται, καθώς και η καταλληλότητα του μοντέλου για το συγκεκριμένο πρόβλημα.

Στην παρούσα εργασία θα ασχοληθούμε με την εφαρμογή της μεθόδου ANFIS στην στο πεδίο της Μηχανικής σχετικά με την **πρόβλεψη παραγωγής ηλεκτρικής ενέργειας από ανεμογεννήτριες**. Στο 4^ο Κεφάλαιο θα γίνει αναλυτική περιγραφή της εφαρμογής της μεθόδου ANFIS **στον Βραχυπρόθεσμο Χρονικό Ορίζοντα Πρόβλεψης 1 Ημέρας (Short - Term One Day ahead)**.

2^ο ΚΕΦΑΛΑΙΟ




ΑΣΑΦΗΣ
ΛΟΓΙΚΗ

ΚΕΦΑΛΑΙΟ 2ο – ΑΣΑΦΗΣ ΛΟΓΙΚΗ

2.1 Εισαγωγή στην Ασαφή Λογική

2.1.1 Γενικά

Η **Ασαφής Λογική** είναι μια επέκταση της Boolean λογικής, από τον καθηγητή Lotfi A. Zadeh (1965, Πανεπιστήμιο της Καλιφόρνιας του Μπέρκλεϋ), με βάση τη μαθηματική θεωρία των ασαφών συνόλων, η οποία είναι μια γενίκευση της κλασικής θεωρίας συνόλων. Εισάγοντας την έννοια του **βαθμού στην επαλήθευση μιας συνθήκης, επιτρέποντας έτσι μια συνθήκη να βρίσκεται σε κατάσταση διαφορετική από την αληθή ή την ψευδή**, η ασαφής λογική παρέχει μια ιδιαιτέρως πολύτιμη ευελιξία για συλλογισμό, καθώς καθιστά δυνατό να ληφθούν υπόψη ανακρίβειες και αβεβαιότητες. Συνεπώς, μια πρόταση δεν είναι απαραίτητα απλά αληθής ή ψευδής, αλλά μπορεί να είναι μερικώς αληθής ή ψευδής.



Εικόνα 2.1 Ακρίβεια VS Σημαντικότητα

Ένα πλεονέκτημα της ασαφούς λογικής, προκειμένου να τυποποιήσει την ανθρώπινη λογική, είναι ότι οι κανόνες τίθενται σε φυσική γλώσσα. Για παράδειγμα, ακολουθούν ορισμένοι κανόνες συμπεριφοράς που ακολουθεί ένας οδηγός, υποθέτοντας ότι δεν θέλει να χάσει την άδεια οδήγησης:

Αν το φανάρι είναι κόκκινο...	αν η ταχύτητά μου είναι υψηλή...	και αν το φανάρι είναι κοντά...	τότε φρενάρω δυνατά.
Αν το φανάρι είναι κόκκινο...	αν η ταχύτητά μου είναι χαμηλή...	και αν το φανάρι είναι μακριά...	τότε διατηρώ την ταχύτητά μου.
Αν το φανάρι είναι πορτοκαλί...	αν η ταχύτητά μου είναι μέτρια...	και αν το φανάρι είναι μακριά...	τότε φρενάρω απαλά.
Αν το φανάρι είναι πράσινο...	αν η ταχύτητά μου είναι χαμηλή...	και αν το φανάρι είναι κοντά...	τότε επιταχύνω.

Από το παραπάνω, φαίνεται ότι οι μεταβλητές εισόδου εκτιμώνται κατά προσέγγιση από τον ανθρώπινο εγκέφαλο, όπως ο βαθμός επαλήθευσης ενός όρου στην ασαφή λογική[8].

2.1.2 Ασαφή Σύνολα

Σύμφωνα με τον διάσημο, για τη Θεωρία συνόλων, μαθηματικό **Γκέοργκ Κάντορ**, ένα **Σύνολο** είναι **Πολλά** που επιτρέπουν στον εαυτό τους να θεωρηθούν ως **Ένα**.

Ως μία γενίκευση των κλασσικών συνόλων, τα ασαφή σύνολα καθιερώθηκαν ως εργαλείο στην επίλυση πληθώρας πρακτικών προβλημάτων, ως ένας τρόπος διαχείρισης της ανακρίβειας και της ασάφειας. Συνεπώς, αυτά τα χαρακτηριστικά αποτελούν και τον πυρήνα των ασαφών συνόλων και της ασαφούς λογικής.

Αντί για τον δυαδικό προσδιορισμό του ανήκειν ή όχι μίας τιμής σε ένα σύνολο, τα ασαφή σύνολα είναι συναρτήσεις που απεικονίζουν μια τιμή, η οποία μπορεί να είναι μέλος του συνόλου, σε έναν αριθμό από το «0» έως το «1», ο οποίος δηλώνει το βαθμό συσχέτισης της τιμής ή τον βαθμό συμμετοχής της στο ασαφές σύνολο. Το ασαφές σύνολο συμπίπτει με το κλασσικό σύνολο μόνο στην περίπτωση που ο βαθμός αυτός είναι «0», και τότε η τιμή δεν ανήκει στο σύνολο, ή όταν ο βαθμός είναι «1» και τότε συνεπάγεται ότι η τιμή αυτή αντιπροσωπεύει πλήρως το ασαφές σύνολο [9].


Η θεωρία των ασαφών συνόλων, αποτελεί μια γενίκευση της κλασσικής θεωρίας συνόλων που σημαίνει ότι η τελευταία αποτελεί μία ειδική περίπτωση, δηλαδή υποσύνολο της θεωρίας των ασαφών συνόλων όπως φαίνεται στο Σχήμα 2.1.



Σχήμα 2.1 Η Κλασσική Λογική Υποσύνολο της Ασαφούς

Τα κλασσικά σύνολα λοιπόν μπορεί να περιέχουν ή όχι μία τιμή ενώ τα ασαφή μπορεί να την περιέχουν έως έναν βαθμό, δηλαδή μπορεί μια πρόταση να είναι αληθής μέχρι κάποιο βαθμό.


Ο βαθμός συσχέτισης μιας τιμής καθορίζεται από τη συνάρτηση συμμετοχής του ασαφούς συνόλου. Για παράδειγμα, το Διάγραμμα 2.2 δείχνει τη συνάρτηση συμμετοχής που επιλέχθηκε για να χαρακτηρίσει το υποσύνολο της «καλής» ποιότητας μιας εξυπηρέτησης.



Διάγραμμα 2.1 Συνάρτηση Συμμετοχής που Χαρακτηρίζει το Υποσύνολο της «Καλής» Ποιότητας Εξυπηρέτησης

Η θεωρία των ασαφών συνόλων αποτελεί μέθοδο για να προσδιορίσουμε κατά πόσο ένα αντικείμενο πληροί μια αόριστη συνθήκη και ενέχει **υποκειμενικότητα** καθώς εξαρτάται από τον τρόπο με τον οποίο κάθε άτομο αντιλαμβάνεται τις γενικές περιγραφές ορισμένων ποσοτικών μεγεθών.

Για παράδειγμα έστω η πρόταση «κάνει κρύο». Για την θερμοκρασία των 10°C, δεν μπορούμε να την χαρακτηρίσουμε αληθή ή ψευδή, γιατί εξαρτάται από το πώς αντιλαμβάνεται ο καθένας την συγκεκριμένη δήλωση. Η ασάφεια λοιπόν, δεν συνίσταται στη γνώση ή όχι της θερμοκρασίας, αλλά στο γεγονός ότι ο γλωσσικός (linguistic) όρος «κρύο» δεν διαχωρίζει τη θερμοκρασία σε δύο κατηγορίες αυστηρά αλλά σε πολλές διαβαθμίσεις (Σχήμα 2. 2).



Σχήμα 2.2 Σχηματική Αναπαράσταση Συμβατικού και Ασαφούς Συνόλου

2.1.3 Διαχωρισμός Ασαφούς Λογικής – Θεωρίας Πιθανοτήτων

Συνοψίζοντας τις ιδιότητες της ασαφούς λογικής, ο **Earl Cox** στο βιβλίο του «Οι Επτά Ευγενείς Αλήθειες της Ασαφούς Λογικής» εισήγαγε επτά προτάσεις που την χαρακτηρίζουν και συγχρόνως την διαχωρίζουν από τη θεωρία των πιθανοτήτων.

1. **Η ασαφής λογική δεν είναι ασαφής** δηλαδή δεν είναι εγγενώς ανακριβής, δεν παραβιάζει την κοινή λογική και παράγει αναμφισβήτητα αποτελέσματα. Στην πραγματικότητα, η «κλασική» δυαδική λογική είναι απλώς μια ειδική περίπτωση της.
2. **Η ασαφής λογική είναι διαφορετική από την θεωρία των πιθανοτήτων** κατά την οποία προσπαθούμε να προσδιορίσουμε κάτι σχετικά με το πιθανό αποτέλεσμα σαφώς καθορισμένων γεγονότων που μπορεί να συμβούν τυχαία. Αντιθέτως με τη ασαφή λογική, προσπαθούμε να προσδιορίσουμε κάτι σχετικά με τη φύση του ίδιου του γεγονότος. Η ασάφεια εκφράζεται συχνά ως αμφιβολία, όχι ως ανακρίβεια ή αβεβαιότητα και αποτελεί χαρακτηριστικό της αντίληψης καθώς και της έννοιας.
3. **Ο σχεδιασμός ασαφών συνόλων είναι εύκολος** καθώς αυτά αντικατοπτρίζουν, με γενικό τρόπο, πώς πραγματικά σκέφτονται οι άνθρωποι ένα πρόβλημα. Έτσι, τις περισσότερες φορές, είναι γρήγορο και εύκολο να προσδιοριστεί το κατά προσέγγιση σχήμα ενός ασαφούς συνόλου και μετά από κάποιες δοκιμές ή λόγω εμπειρίας, μπορούν να προσαρμοστούν τα ακριβή χαρακτηριστικά του.
4. **Τα ασαφή συστήματα είναι σταθερά, εύκολα ρυθμίσιμα και επαληθεύσιμα.** Είναι πιο γρήγορη και πιο εύκολη η δημιουργία ασαφών συνόλων και συστημάτων από ό,τι η δημιουργία συμβατικών συστημάτων που βασίζονται στη γνώση, καθώς η ασαφής λογική χειρίζεται όλους τους

εμπλεκόμενους βαθμούς ελευθερίας. Αυτά τα συστήματα επαληθεύονται όπως τα συμβατικά, αλλά ο συντονισμός τους είναι συνήθως πολύ πιο απλός.

5. **Τα ασαφή συστήματα δεν είναι νευρωνικά δίκτυα.** Ένα ασαφές σύστημα επιχειρεί να βρει την τομή, την ένωση ή το συμπλήρωμα των ασαφών μεταβλητών ελέγχου. Αν και αυτό είναι κάπως ανάλογο τόσο με τα νευρωνικά δίκτυα όσο και με τον γραμμικό προγραμματισμό, τα ασαφή συστήματα προσεγγίζουν διαφορετικά αυτά τα προβλήματα.
6. **Η ασαφής λογική είναι κάτι περισσότερο από έλεγχος διαδικασίας.** Αν και μερικοί άνθρωποι βλέπουν τη ασαφή λογική κυρίως ως εργαλείο για τον έλεγχο της διαδικασίας και την ανάλυση σήματος, αυτή η ερμηνεία είναι πολύ περιοριστική. Η ασαφής λογική είναι ένας τρόπος αναπαράστασης και ανάλυσης πληροφοριών, ανεξάρτητος από συγκεκριμένες εφαρμογές.
7. **Η ασαφής λογική είναι μια διαδικασία αναπαράστασης και συλλογιστικής.** Η ασαφής λογική είναι ένα ισχυρό και ευέλικτο εργαλείο για την αναπαράσταση ανακριβών, διφορούμενων και αόριστων πληροφοριών. Δεν μπορεί να λύσει όλα τα προβλήματα, αλλά μας βοηθά να μοντελοποιήσουμε δύσκολα, ακόμη και δυσεπίλυτα προβλήματα [10].

2.2 Εφαρμογές, πλεονεκτήματα και περιορισμοί

Τα τελευταία χρόνια, ο αριθμός και η ποικιλία των εφαρμογών της ασαφούς λογικής έχουν αυξηθεί σημαντικά καθώς είναι **μία ευρέως αποδεκτή μέθοδος σε πολλές επιστημονικές και ερευνητικές περιοχές, για την επίλυση μη γραμμικών προβλημάτων με υψηλό βαθμό αβεβαιότητας**. Οι εφαρμογές κυμαίνονται από καταναλωτικά προϊόντα όπως κάμερες, βιντεοκάμερες, αντικλεπτικά συστήματα, οικιακές συσκευές όπως πλυντήρια ρούχων και φούρνους μικροκυμάτων έως τον έλεγχο βιομηχανικών διεργασιών, συστημάτων αυτομάτου ελέγχου, μετεωρολογικών συστημάτων, ιατρικών οργάνων, αλλά και σε συστήματα υποστήριξης αποφάσεων και επιλογής χαρτοφυλακίου.

2.2.1 Πλεονεκτήματα Ασαφούς Λογικής

Η χρήση της ασαφούς λογικής προσφέρει πολλά πλεονεκτήματα:

- **Εννοιολογική απλότητα** καθώς οι μαθηματικές έννοιες που διέπουν τη ασαφή λογική είναι απλές και κατανοητές. Αυτό το καθιστά μια διαισθητική προσέγγιση, αποφεύγοντας την υπερβολική πολυπλοκότητα.
- **Ευελιξία** η οποία επιτρέπει την εύκολη προσθήκη περισσότερων λειτουργιών σε ένα δεδομένο σύστημα χωρίς να χρειάζεται εκκίνηση από την αρχή.
- **Ανοχή ανακριβών δεδομένων.** Διαπιστώνοντας ότι τα δεδομένα είναι συχνά εγγενώς ανακριβή, η ασαφής λογική ενσωματώνει αυτή την κατανόηση στη διαδικασία αυτή καθαυτή, αντί να την αντιμετωπίζει ως μια μεταγενέστερη σκέψη.
- **Μοντελοποίηση πολύπλοκων μη γραμμικών συναρτήσεων** με βάση δεδομένα εισόδου – εξόδου. Τεχνικές όπως η ANFIS απλοποιούν περαιτέρω αυτή τη διαδικασία.
- **Μόχλευση τεχνογνωσίας.** Αντιθέτως με τα νευρωνικά δίκτυα, τα οποία δημιουργούν αδιαφανή και αδιαπέραστα μοντέλα, η ασαφής λογική επιτρέπει την αξιοποίηση της τεχνογνωσίας ειδικών που ήδη κατανοούν το σύστημα.
- **Ενσωμάτωση με συμβατικές τεχνικές ελέγχου.** Τα ασαφή συστήματα δεν αντικαθιστούν απαραίτητα τις συμβατικές μεθόδους ελέγχου, αλλά μπορούν να λειτουργήσουν σε συνδυασμό με αυτές, ενισχύοντας και απλοποιώντας ενδεχομένως την εφαρμογή τους.
- **Η ασαφής λογική βασίζεται στη φυσική γλώσσα.** Η ασαφής λογική έχει τις ρίζες της στις δομές της φυσικής γλώσσας, η οποία είναι το θεμέλιο της ανθρώπινης επικοινωνίας. Η ασαφής λογική είναι εύκολη στη χρήση, επειδή βασίζεται στις δομές της ποιοτικής περιγραφής που χρησιμοποιούνται στην καθημερινή γλώσσα [11].

2.2.2 Περιορισμοί Ασαφούς Λογικής

Ένα από τα μειονεκτήματα της ασαφούς λογικής είναι ότι **τα αποτελέσματα της δεν είναι πάντα ακριβώς σωστά**, λόγω του ότι βασίζονται σε εικασίες. Ένας ακόμη περιορισμός είναι ότι για να είναι αποτελεσματική η εφαρμογή ενός ασαφούς συστήματος, ισχύει η προϋπόθεση να έχει ο ειδικός **αρκετή γνώση για την εξεταζόμενη διαδικασία**. Όταν δεν συμβαίνει αυτό, τότε περιορίζεται σημαντική η δυνατότητα εφαρμογής ασαφών

συστημάτων. Επιπλέον, στα ασαφή σύνολα, **δυσκολία παρουσιάζει η ακριβής οριοθέτηση του χώρου εισόδων και εξόδων ενός προβλήματος, ο καθορισμός των τιμών των παραμέτρων στις συναρτήσεις συμμετοχής καθώς και το πλήθος των ασαφών κανόνων**, με αποτέλεσμα την περιορισμένη αξιοποίηση της σημαντικής ισχύος που χαρακτηρίζει την ασαφή λογική [12].

2.3 Ασαφή Σύνολα και Συναρτήσεις Συμμετοχής

2.3.1 Ασαφές Σύνολο – Ορισμός

Ένα ασαφές σύνολο A (fuzzy set) ορίζεται ως ένα σύνολο διατεταγμένων ζευγών $(x, \mu_A(x))$ όπου το $x \in X$ και το $\mu_A(x) \in [0, 1]$. Το σύνολο X αποτελεί ένα ευρύτερο σύνολο αναφοράς (universe of discourse) που περιλαμβάνει όλα τα αντικείμενα στα οποία μπορεί να γίνει αναφορά. Η μ_A ονομάζεται **συνάρτηση συμμετοχής (membership function)** και η τιμή $\mu_A(x)$ ονομάζεται **βαθμός αλήθειας (degree of truth)**, συμβολίζει τον βαθμό συμμετοχής του x στο A και παίρνει τιμές στο διάστημα $[0, 1]$. Η διαφορά των ασαφών συνόλων συγκριτικά με την κλασσική θεωρία συνόλων είναι ότι στην κλασσική θεωρία συνόλων ισχύει $\mu_A(x) \in \{0, 1\}$, δηλαδή το x είτε ανήκει στο A ($\mu_A(x) = 1$) ή δεν ανήκει στο A ($\mu_A(x) = 0$). Άρα η ασαφής θεωρία συνόλων μεταπίπτει στην αντίστοιχη κλασσική, όταν οι δυνατές τιμές της συνάρτησης συμμετοχής είναι μόνο 0 ή 1. Για τα ασαφή σύνολα ορίζονται πράξεις και ισχύουν ιδιότητες ανάλογες με αυτές που ισχύουν στα κλασσικά σύνολα.

Πίνακας 2.1 Κλασσικά VS Ασαφή Σύνολα

Κλασσικά Σύνολα
<ul style="list-style-type: none"> • Ένα στοιχείο είναι μέλος ή όχι • Αληθές ή ψευδές είναι οι μόνες δυνατότητες
Ασαφή Σύνολα
<ul style="list-style-type: none"> • Ένα αντικείμενο μπορεί να ανήκει μερικώς σε ένα σύνολο • Ο βαθμός συμμετοχής στο σύνολο ονομάζεται συνάρτηση συμμετοχής $f(x)$ • $f(x)=0$ το αντικείμενο δεν ανήκει στο σύνολο • $f(x)=1$ είναι σίγουρα μέλος του συνόλου • Οι υπόλοιπες τιμές για την $f(x)$ δείχνουν το βαθμό συμμετοχής

Το ασαφές σύνολο ορίζεται ως:

$$A = \sum_{x_i \in X} \mu_A(x_i) / (x_i), \quad \text{όταν το } X \text{ είναι ένα σύνολο διακριτών αντικειμένων και}$$

$A = \int_X \mu_A(x)/x$, όταν το X είναι ένα συνεχές διάστημα (συνήθως το R^+)

Στην πράξη η συνάρτηση συμμετοχής μπορεί να προέρχεται από:

- Υποκειμενικές εκτιμήσεις
- Προκαθορισμένες (ad hoc) και απλοποιημένες μορφές
- Συχνότητες εμφανίσεων και πιθανότητες
- Φυσικές μετρήσεις
- Διαδικασίες μάθησης και προσαρμογής (π.χ. με νευρωνικά δίκτυα)[13]

E: Είναι το Σάββατο ημέρα Σαββατοκύριακου;

A: 1 (ναι ή αλήθεια)

E: Είναι η Τρίτη ημέρα Σαββατοκύριακου;

A: 0 (όχι ή λάθος)

E: Είναι η Παρασκευή ημέρα Σαββατοκύριακου;


A: 0,8 (ως επί το πλείστον ναι, αλλά όχι εντελώς)

E: Είναι η Κυριακή ημέρα Σαββατοκύριακου;

A: 0,95 (ναι, αλλά όχι τόσο όσο το Σάββατο).


Η συλλογιστική σε ασαφή λογική έχει σημασία για τη γενίκευση της γνωστής λογικής «ναι – όχι» (Boolean). Εάν θέσουμε ως «αλήθεια» την αριθμητική τιμή του 1 και «λάθος» την αριθμητική τιμή του 0, αυτό υποδηλώνει ότι η ασαφής λογική επιτρέπει επίσης ενδιάμεσες τιμές όπως το 0,2 και το 0,7453. Για παράδειγμα:

Η ακόλουθη γραφική παράσταση (Διάγραμμα 3.2) στα αριστερά δείχνει τις τιμές αλήθειας για το Σαββατοκύριακο, εάν οι απαντήσεις δοθούν αναγκαστικά με απόλυτο τρόπο δηλαδή ως «ναι» ή «όχι». Δεξιά είναι η γραφική παράσταση που δείχνει την τιμή αλήθειας για το Σαββατοκύριακο, εάν δοθούν ασαφείς απαντήσεις επιλέγοντας ενδιάμεσες τιμές.



Διάγραμμα 2.2 Δυναδική Λογική VS Ασαφή Λογική

Τεχνικά, η αναπαράσταση στα δεξιά προέρχεται από τον τομέα της λογικής πολλαπλών τιμών. Στην ερώτηση "Είναι το X μέλος του συνόλου A;" η απάντηση μπορεί να είναι «ναι», «όχι» ή οποιαδήποτε από τις χίλιες ενδιάμεσες τιμές. Έτσι, το X μπορεί να έχει μερική συμμετοχή στο A. Η λογική πολλαπλών τιμών έρχεται σε άμεση αντίθεση με την πιο οικεία έννοια της λογικής δύο τιμών. Στο Διάγραμμα 3.3 αποτυπώνεται γραφικά η παράσταση χρόνου συνεχούς κλίμακας του Σαββατοκύριακου για συνάρτηση δύο τιμών και συνάρτηση πολλαπλών τιμών.



Διάγραμμα 2.3 Γραφική Παράσταση Χρόνου Συνεχούς Κλίμακας Σαββατοκύριακου

Κάνοντας το γράφημα συνεχές, ορίζουμε τον βαθμό στον οποίο κάθε δεδομένη στιγμή ανήκει στο Σαββατοκύριακο και όχι σε μια ολόκληρη μέρα. Στο γράφημα στα αριστερά, παρατηρούμε ότι τα μεσάνυχτα της Παρασκευής, ακριβώς τη στιγμή που δείχνει 00.00, η τιμή της αλήθειας του Σαββατοκύριακου μεταπηδά ασυνεχώς από το 0 στο 1. Αυτός είναι ένας τρόπος για να ορίσουμε το Σαββατοκύριακο, και ενώ μπορεί να είναι χρήσιμο π.χ. σε έναν λογιστή, μπορεί να μην συνδέεται με την πραγματική εμπειρία του Σαββατοκύριακου. Το γράφημα στα δεξιά, δείχνει μία ομαλά μεταβαλλόμενη καμπύλη που εξηγεί το γεγονός ότι όλη την Παρασκευή και, σε μικρό βαθμό, μέρος της Πέμπτης, απολαμβάνουν την ποιότητα του Σαββατοκύριακου και έτσι αξίζουν μερική

συμμετοχή στο ασαφές σύνολο στιγμών του Σαββατοκύριακου. Η καμπύλη που καθορίζει το Σαββατοκύριακο οποιασδήποτε χρονικής στιγμής είναι μια συνάρτηση που αντιστοιχίζει το χώρο εισόδου (ώρα της εβδομάδας) στο χώρο εξόδου (Σαββατοκύριακο) [11].

2.3.2 Μορφές Συναρτήσεων Συμμετοχής


Στη συνέχεια παρουσιάζονται διάφορες μορφές μονοδιάστατων παραμετρικών συναρτήσεων συμμετοχής, δηλαδή συναρτήσεων που εξαρτώνται από μία μοναδική είσοδο (input). Οι απλούστερες συναρτήσεις συμμετοχής δημιουργούνται χρησιμοποιώντας ευθείες γραμμές.

1. Triangular MF ή trimf. Η απλούστερη είναι η τριγωνική συνάρτηση συμμετοχής. Προσδιορίζεται από τρεις παραμέτρους $\{a, b, c\}$ (όπου $a < b < c$) οι οποίες καθορίζουν τις συντεταγμένες x των τριών γωνιών της συγκεκριμένης τριγωνικής συνάρτησης, ως εξής:

$$\text{trimf}(x, a, b, c) = \max\left(\min\left(\frac{x-a}{b-a}, \frac{c-x}{c-b}\right), 0\right)$$

Η μαθηματική έκφραση της τριγωνικής συνάρτησης συμμετοχής είναι η εξής:

$$A = \begin{cases} 0, & x \leq a \\ \frac{(x-a)}{(b-a)}, & x \in (a, b) \\ \frac{(c-x)}{(c-b)}, & x \in (b, c) \\ 0, & x \geq c \end{cases}$$




Διάγραμμα 2.4 Τριγωνική Συνάρτηση Συμμετοχής

2. Trapezoidal MF ή trapmf. Ομοίως, η τραπεζοειδής συνάρτηση συμμετοχής καθορίζεται από τέσσερις παραμέτρους $\{a, b, c, d\}$ (όπου $a < b < c < d$) οι οποίες καθορίζουν τις συντεταγμένες x των τεσσάρων γωνιών της συγκεκριμένης τραπεζοειδούς συνάρτησης, ως εξής:

$$\text{trimf}(x, a, b, c, d) = \max\left(\min\left(\frac{x-a}{b-a}, 1, \frac{d-x}{d-c}\right), 0\right)$$

Η μαθηματική έκφραση της τραπεζοειδούς συνάρτησης συμμετοχής είναι η εξής:

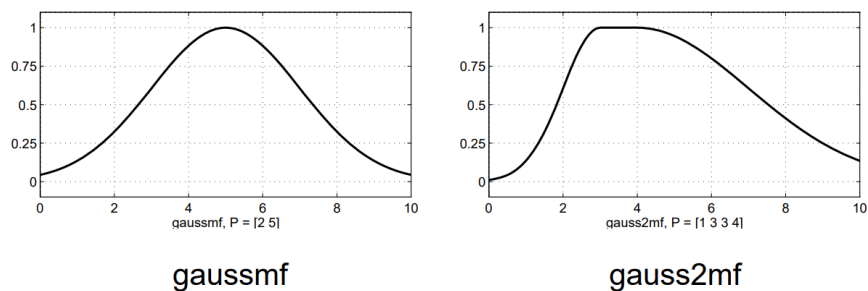
$$A = \begin{cases} 0, x \leq a \\ \frac{(x-a)}{(b-a)}, x \in (a, b) \\ 1, x \in (b, c) \\ \frac{(d-x)}{(d-c)}, x \in (c, d) \end{cases}$$



Διάγραμμα 2.5 Τραπεζοειδής Συνάρτηση Συμμετοχής

3. **Gaussian MF.** Δύο συναρτήσεις συμμετοχής είναι χτισμένες στην καμπύλη κατανομής Gauss: μια απλή γκαουσιανή καμπύλη *gaussmf* και ο συνδυασμός δύο διαφορετικών γκαουσιανών καμπυλών *gauss2mf*. Η γκαουσιανή συνάρτηση συμμετοχής ορίζεται από δυο παραμέτρους $\{c, \sigma\}$, όπου το c αναπαριστά το κέντρο της και το σ το πλάτος της.

$$gaussmf(x, c, \sigma) = e^{-\frac{1}{2}\left(\frac{x-c}{\sigma}\right)^2}$$




Διάγραμμα 2.6 Γκαουσιανές Συναρτήσεις Συμμετοχής

4. **Generalized bell MF.** Η γενικευμένη καμπανοειδής συνάρτηση συμμετοχής έχει μία παραπάνω παράμετρο από τη γκαουσιανή, καθορίζεται δηλαδή από τρεις παραμέτρους $\{a, b, c\}$, επομένως μπορεί να προσεγγίσει ένα μη ασαφές σύνολο εάν συντονιστεί η ελεύθερη παράμετρος.

$$gbellmf(x, a, b, c) = \frac{1}{1 + \left|\frac{x-c}{a}\right|^{2b}}$$

Λόγω της ομαλότητάς τους, οι γκαουσιανές και οι καμπανοειδείς συναρτήσεις είναι δημοφιλείς μέθοδοι για τον καθορισμό ασαφών συνόλων καθώς και οι δύο

αυτές καμπύλες έχουν το πλεονέκτημα να διατηρούν μη μηδενικές σε όλα τα σημεία.




Διάγραμμα 2.7 Καμπανοειδής Συνάρτηση Συμμετοχής

5. Sigmoidal MF. Αν και οι γκαουσιανές και οι καμπανοειδής συναρτήσεις συμμετοχής επιτυγχάνουν ομαλότητα, δεν είναι σε θέση να καθορίσουν ασύμμετρες συναρτήσεις συμμετοχής, οι οποίες είναι σημαντικές σε πολλά πρακτικά προβλήματα. Για το λόγο αυτό ορίζεται η σιγμοειδής συνάρτηση συμμετοχής, η οποία είναι ανοιχτή είτε αριστερά είτε δεξιά.

$$\text{sigmf}(x, a, c) = \frac{1}{1 + \exp[-a(x - c)]}$$


Οι ασύμμετρες και κλειστές (δηλαδή όχι ανοιχτές αριστερά ή δεξιά) συναρτήσεις συμμετοχής μπορούν να συντεθούν χρησιμοποιώντας δύο σιγμοειδείς συναρτήσεις. Έτσι εκτός από τη βασική sigmf , υπάρχει επίσης η διαφορά μεταξύ δύο σιγμοειδών συναρτήσεων dsigmf καθώς και το άθροισμα δύο σιγμοειδών συναρτήσεων psigmf .



Διάγραμμα 2.8 Σιγμοειδής Συναρτήσεις Συμμετοχής

6. Polynomial based curves. Πολλές πολυωνυμικές καμπύλες χρησιμοποιούνται ως συναρτήσεις συμμετοχής. Οι τρεις πιο σχετικές είναι οι καμπύλες Z, S, και Π και ονομάστηκαν καταυτόν τον τρόπο λόγω του σχήματός τους. Η Z είναι η ασύμμετρη πολυωνυμική καμπύλη ανοιχτή προς τα αριστερά, η S είναι η συνάρτηση κατοπτρικής εικόνας που ανοίγει προς τα δεξιά και η Π

είναι μηδέν και στα δύο άκρα με άνοδο στη μέση, δηλαδή μια ασύμμετρη κλειστή καμπύλη σχήματος Π [11].




Διάγραμμα 2.9 Πολυωνυμικές Καμπύλες Z, S, Π

2.3.3 Κατασκευή Συναρτήσεων Συμμετοχής

Στον σχεδιασμό της συνάρτησης συμμετοχής υπάρχουν κάποιες παράμετροι και κάποιοι περιορισμοί που οφείλουμε να τους λάβουμε υπόψη.


Ανάλογα με τις τιμές των ορίων των περιοχών μπορούμε να είμαστε ελαστικοί ή αυστηροί ως προς τον χαρακτηρισμό των σημείων ως «μεσαία».

Ελαστικότητα ως προς τον χαρακτηρισμό «μεσαία»: Όταν ορίζουμε μεγάλη περιοχή γύρω από το μέση τιμή για την οποία τα άτομα θεωρούνται «μεσαία» και αντίστοιχα μικρές περιοχές στα άκρα των αξόνων για τις οποίες τα άτομα θεωρούνται «χαμηλά» ή «υψηλά».



Διάγραμμα 2.10 Ελαστικότητα ως προς τον Χαρακτηρισμό «Μεσαία»

Αυστηρότητα ως προς τον χαρακτηρισμό «μεσαία»: Όταν ορίζουμε μικρή περιοχή γύρω από τη μέση τιμή για την οποία τα άτομα θεωρούνται «μεσαία» και αντίστοιχα μεγάλες περιοχές στα άκρα των αξόνων για τις οποίες τα άτομα θεωρούνται «χαμηλά» ή «υψηλά».



Διάγραμμα 2.11 Αυστηρότητα ως προς τον Χαρακτηρισμό «Μεσαία»

Ένα σημαντικό θέμα για τις συναρτήσεις συμμετοχής είναι η **συμμετρία**. Συμμετρική είναι μια συνάρτηση συμμετοχής όταν το άθροισμα των βαθμών συμμετοχής όλων των ατόμων για όλες τις περιοχές ισούται με 1.

Συμμετρικός δηλαδή θεωρείται ένας κανόνας όταν ισχύει η παρακάτω σχέση:


$$\mu_{ij}^x + \mu_{ij}^m + \mu_{ij}^y = 1$$

Από τους παραπάνω ορισμούς και προκειμένου να έχει νόημα ο ορισμός των συναρτήσεων συμμετοχής προκύπτει ο **περιορισμός** της επόμενης σχέσης για τις τιμές συμμετοχής στις τρεις περιοχές:

$$0 = \sum_{A=1}^3 \mu_{ij}^{CA} \leq 1$$

Από αυτό τον περιορισμό προκύπτει ότι τα όρια των τριών περιοχών όπως φαίνονται στο Διάγραμμα 3.11 πρέπει να ικανοποιούν τις εξής ανισότητες:

- $D \geq B$, δηλαδή το κάτω αριστερό όριο της «μεσαίας» περιοχής πρέπει να έχει τιμή μεγαλύτερη ή ίση του άνω δεξιού ορίου της «χαμηλής» περιοχής
- $E \geq C$, δηλαδή το άνω αριστερό όριο της «μεσαίας» περιοχής πρέπει να έχει τιμή μεγαλύτερη ή ίση του κάτω δεξιού ορίου της «χαμηλής» περιοχής
- $F \leq H$, δηλαδή το άνω δεξιό όριο της «μεσαίας» περιοχής πρέπει να έχει τιμή μικρότερη ή ίση του κάτω αριστερού ορίου της «υψηλής» περιοχής
- $G \leq I$, δηλαδή το κάτω δεξιό όριο της «μεσαίας» περιοχής πρέπει να έχει τιμή μικρότερη ή ίση του άνω αριστερού ορίου της «υψηλής» περιοχής



Διάγραμμα 2.12 Συμμετρία Συνάρτησης Συμμετοχής

2.4 Ιδιότητες και Λογικές Πράξεις

2.4.1 Ιδιότητες Ασαφών Συνόλων

Έστω X ένα σύνολο αντικειμένων, του οποίου τα στοιχεία συμβολίζονται με το γράμμα x . Η συμμετοχή σε ένα υποσύνολο A του συνόλου X είναι μια συνάρτηση συμμετοχής μ_A από το X στο διάστημα $[0, 1]$. Το A είναι ένα ασαφές υποσύνολο του X , το οποίο όμως δεν έχει αυστηρά καθορισμένα σύνορα και μ_A είναι ο βαθμός συμμετοχής του στοιχείου x στο A . Όσο πιο κοντά στο 1 είναι το μ_A τόσο πιο πολύ ανήκει το x στο A .

Το σύνολο A μπορεί να προσδιοριστεί επομένως από το σύνολο των παρακάτω ζευγών:

$$A = \{(x, \mu_A(x)), x \in X\}$$

Κάθε ζευγάρι $(x, \mu_A(x))$ ονομάζεται **μονοσύνολο**.

Χώρος αναφοράς του ασαφούς συνόλου A είναι το σύνολο των στοιχείων του X που έχουν μη μηδενικό βαθμό συμμετοχής στο A .

$$\text{Supp } A = \{x \in X | \mu_A(x) > 0\}.$$

Το σύνολο A μπορεί να γραφεί και ως:

$$A = \mu_1/x_1 + \mu_2/x_2 + \dots$$

$$A = \sum \mu_i/x_i$$

Στο συνεχή χώρο αναφοράς :

$$A = \int_x \mu_A(x)/x$$

Ασαφές δυναμοσύνολο

Ασαφές δυναμοσύνολο $F(x)$ του υπερσυνόλου αναφοράς X , ονομάζεται το σύνολο όλων των ασαφών υποσυνόλων του X .

Υποσύνολο

Το σύνολο A είναι υποσύνολο του B , $A \subseteq B$ αν και μόνο αν

$$\mu_A(x) \leq \mu_B(x), \forall x \in X$$

Αν ταυτόχρονα τα A και B δεν είναι ίσα, τότε το A θα ονομάζεται γνήσιο υποσύνολο του B .

Ασαφής διαμέριση

Μια οικογένεια ασαφών υποσυνόλων του X , θα λέγεται ασαφής διαμέριση $P^n(X)$ του X τάξης n ($n \in N$) και θα συμβολίζεται με $A^n = \{A_1, A_2, \dots, A_n\}$, αν και μόνο αν:

$$A_j \neq A_i, \forall i, j \in N_n (i \neq j)$$

$$0 < \sum_{k=1}^m A_i(x_k) < m, \forall i \in N_n$$

Τα στοιχεία A_i $i \in N_n$ της A_n θα λέγονται κλάσεις της ασαφούς διαμέρισης.

Κενό ασαφές σύνολο

Ένα ασαφές σύνολο με χώρο αναφοράς τον X , λέγεται κενό αν για κάθε στοιχείο x που ανήκει στον X , η συνάρτηση συμμετοχής του A είναι μηδέν.

$$0 \equiv A \text{ αν } \mu_A(x) = 0 \quad \forall x \in X$$

Κανονικό ασαφές σύνολο

Ένα ασαφές σύνολο A που ορίζεται στο χώρο αναφοράς X , λέγεται κανονικό αν υπάρχει τουλάχιστο ένα στοιχείο x του X για το οποίο η συνάρτηση συμμετοχής να παίρνει τιμή ίση με τη μονάδα.

$$A = \text{κανονικό αν } \exists x_1 : \mu_A(x_1) = 1$$

Ισότητα ασαφών συνόλων

Δύο ασαφή σύνολα A και B που ορίζονται στο χώρο αναφοράς X , λέγονται ίσα αν για κάθε στοιχείο x του X οι συναρτήσεις συμμετοχής των A και B είναι ίσες. Δηλαδή:

$$A = B \text{ αν } \mu_A(x) = \mu_B(x) \quad \forall x \in X$$

Συστολή ασαφών συνόλων

Έστω ασαφές σύνολο A που ορίζεται στο χώρο αναφοράς X . Η συστολή, $CON(A)$ του συνόλου αυτού είναι ένα νέο ασαφές σύνολο με συνάρτηση συμμετοχής που ορίζεται ως εξής:

$$\mu_{CON(A)}(x) = (\mu_A(x))^2$$

Η συστολή του ασαφούς συνόλου αντιστοιχεί στην προσθήκη του όρου πολύ, μπροστά από τη λεκτική μεταβλητή που περιγράφει το ασαφές σύνολο. Δηλαδή η συστολή του ασαφούς συνόλου ψηλός είναι ένα νέο ασαφές σύνολο που αντιστοιχεί στην έννοια πολύ ψηλός.

Διαστολή ασαφών συνόλων

Αντιστοίχως η διαστολή ενός ασαφούς συνόλου A , είναι ένα νέο ασαφές σύνολο που συμβολίζεται με $DIL(A)$ και έχει συνάρτηση συμμετοχής που περιγράφεται από την παρακάτω σχέση:

$$\mu_{DIL(A)}(x) = \sqrt{\mu_A(x)}$$

Η διαστολή του ασαφούς συνόλου αντιστοιχεί στην προσθήκη του όρου λίγο, μπροστά από τη λεκτική μεταβλητή που περιγράφει το ασαφές σύνολο. Δηλαδή η διαστολή του ασαφούς συνόλου ψηλός είναι ένα νέο ασαφές σύνολο που αντιστοιχεί στην έννοια λίγο ψηλός [13].

2.4.2 Λογικές Πράξεις Ασαφών Συνόλων

Το σημαντικότερο γεγονός σχετικά με τη ασαφή λογική είναι ότι είναι ένα υπερσύνολο της τυπικής λογικής Boole. Με άλλα λόγια, εάν διατηρηθούν οι ασαφείς τιμές στα άκρα τους, 1 ως εντελώς αληθές και 0 ως εντελώς ψευδές, θα ισχύουν οι τυπικές λογικές πράξεις. Παράδειγμα αποτελούν οι παρακάτω τυπικοί πίνακες αλήθειας.

Πίνακας 2.2 Λογικοί Τελεστές AND, OR, NOT στην Λογική Boole

A	B	A and B
0	0	0
0	1	0
1	0	0
1	1	1

AND

A	B	A or B
0	0	0
0	1	1
1	0	1
1	1	1

OR

A	not A
0	1
1	0

NOT

Στην ασαφή λογική η αλήθεια οποιασδήποτε δήλωσης είναι θέμα βαθμού συμμετοχής. Επομένως ο πίνακας αυτός πρέπει να μετατραπεί με τρόπο που να συμπεριλαμβάνει αυτήν την αρχή. Οι τιμές εισαγωγής A και B μπορεί να είναι πραγματικοί αριθμοί μεταξύ 0 και 1. Πρέπει λοιπόν να βρεθεί μια συνάρτηση

που να διατηρεί τις ιδιότητες της συνάρτησης AND και ταυτόχρονα να μπορεί να επεκτείνεται σε όλους τους πραγματικούς αριθμούς μεταξύ 0 και 1.

Μια πιθανή απάντηση είναι χρησιμοποιώντας τη συνάρτηση $\min(A, B)$, δηλαδή την ελάχιστη τιμή των εισόδων A AND B , όπου τα A και B περιορίζονται στο εύρος $(0,1)$. Χρησιμοποιώντας τον ίδιο συλλογισμό, μπορεί να αντικατασταθεί και ο τελεστής OR με τη συνάρτηση $\max(A, B)$, έτσι ώστε το $A OR B$ να γίνει ισοδύναμο με το $\max(A, B)$. Τέλος, ο τελεστής $NOT A$ γίνεται ισοδύναμος με την πράξη $1 - A$. Ο προηγούμενος πίνακας αλήθειας παραμένει εντελώς αμετάβλητος από αυτές τις αντικαταστάσεις.

Πίνακας 2.3 Λογικοί Τελεστές AND , OR , NOT στην Ασαφή Λογική


A	B	$\min(A, B)$
0	0	0
0	1	0
1	0	0
1	1	1
AND		

A	B	$\max(A, B)$
0	0	0
0	1	1
1	0	1
1	1	1
OR		

A	$1 - A$
0	1
1	0
NOT	

Επιπλέον, επειδή υπάρχει μια συνάρτηση πίσω από τον πίνακα αλήθειας και όχι μόνο ο ίδιος ο πίνακας αλήθειας, μπορούν να εξεταστούν και άλλες τιμές πέρα από το 1 και το 0.

Παρακάτω, ο πίνακας αλήθειας μετατρέπεται σε μια γραφική παράσταση δύο ασαφών συνόλων που εφαρμόζονται μαζί για τη δημιουργία ενός ασαφούς συνόλου. Στο επάνω μέρος εμφανίζονται γραφικές παραστάσεις που αντιστοιχούν στους προηγούμενους πίνακες αλήθειας δύο τιμών, ενώ στο κάτω μέρος βλέπουμε πώς λειτουργούν οι πράξεις σε ένα συνεχώς μεταβαλλόμενο εύρος τιμών αλήθειας A και B , από 0 έως 1, σύμφωνα με τις ασαφείς πράξεις που έχουν οριστεί (AND OR NOT).



Διάγραμμα 2.13 Γραφική Απεικόνιση Τελεστών στην Λογική Boole και στην Ασαφή Λογική

Με βάση τα παραπάνω, έχει οριστεί η τομή *AND* με τον τελεστή *min*, η ένωση *OR* με τον τελεστή *max* και το συμπλήρωμα *NOT* με τον τελεστή $1 - A$, ενός ασαφούς συνόλου, πράξεις που χρησιμοποιούνται πολύ συχνά στα ασαφή σύνολα [11].

Ασαφής Τομή

Γενικά η τομή δύο ασαφών συνόλων μπορεί να παρασταθεί με μια δυαδική απεικόνιση *T* που αθροίζει (aggregates) τις δύο συναρτήσεις συμμετοχής ως ακολούθως:

$$\mu_{A \cap B} = T(\mu_A(x), \mu_B(x))$$

Για παράδειγμα ο δυαδικός τελεστής *T* μπορεί να αντιπροσωπεύει τον πολλαπλασιασμό των $\mu_A(x)$ και $\mu_B(x)$. Αυτού του είδους οι τελεστές τομής αναφέρονται συνήθως ως *t* - νόρμες (τριγωνική νόρμα, triangular norm) και πρέπει να ικανοποιούν τις παρακάτω προϋποθέσεις:

- **Οριακές συνθήκες:** $T(0,0) = 0, T(a,1) = T(1,a) = a$
- **Μονοτονία:** $T(a,b) \leq T(c,d)$ αν $a \leq c$ και $b \leq d$
- **Αντιμεταθετικότητα:** $T(a,b) = T(b,a)$
- **Προσεταιριστικότητα:** $T(a,T(b,c)) = T(T(a,b),c)$

Η πρώτη απαίτηση επιβάλλει τη γενίκευση σε σύνολα διακριτών τιμών (crisp sets). Η δεύτερη υπονοεί ότι μια μείωση του βαθμού συμμετοχής στο *A* ή στο *B* δεν μπορεί να οδηγήσει σε αύξηση του βαθμού συμμετοχής στην τομή των *A* και *B*. Η τρίτη απαίτηση δείχνει ότι ο τελεστής είναι αδιάφορος στον τρόπο

διάταξης με τον οποίο τέμνονται τα δύο σύνολα A και B . Τέλος η τέταρτη απαίτηση μας επιτρέπει να παίρνουμε την τομή οποιουδήποτε αριθμού συνόλων σε οποιαδήποτε διάταξη ζευγών.

Παραδείγματα τ – νορμών είναι:

- Συνήθης τομή $T(a, b) = \min(a, b)$
- Αλγεβρικό γινόμενο $T(a, b) = ab$
- Φραγμένη διαφορά $T(a, b) = \max(0, a + b - 1)$
- Συνάρτηση Hamacher $t(a, b) = \frac{ab}{r + (1-r)(a+b-ab)}$

Ασαφής Ένωση

Όπως η ασαφής τομή έτσι και η ασαφής ένωση προσδιορίζεται με μια δυαδική απεικόνιση S .

$$\mu_{A \cup B} = S(\mu_A(x), \mu_B(x))$$

Για παράδειγμα ο τελεστής S μπορεί να είναι το άθροισμα των $\mu_A(x)$ και $\mu_B(x)$. Οι ασαφείς τελεστές ένωσης αναφέρονται συνήθως ως σ – νόρμες και πρέπει να πληρούν τις παρακάτω προϋποθέσεις:

- **Οριακές συνθήκες:** $S(1,1) = 1, S(a, 0) = S(0, a) = a$
- **Μονοτονία:** $S(a, b) \leq S(c, d)$ αν $a \leq c$ και $b \leq d$
- **Αντιμεταθετικότητα:** $S(a, b) = S(b, a)$
- **Προσεταιριστικότητα:** $S(a, S(b, c)) = S(S(a, b), c)$

Παραδείγματα σ – νορμών είναι τα εξής:

- Συνήθης ένωση $s(a, b) = \max(a, b)$
- Αλγεβρικό άθροισμα $s(a, b) = a + b - ab$
- Φραγμένο άθροισμα $s(a, b) = \min(1, a + b)$

Συμπλήρωμα

Το συμπλήρωμα A' ενός ασαφούς συνόλου A δίνεται από τη σχέση:

$$\mu_{\bar{A}}(x) = c(\mu_A(x))$$

όπου η συνάρτηση c πρέπει να ικανοποιεί τις παρακάτω συνθήκες:

- **Οριακές συνθήκες:** $c(0) = 1$ και $c(1) = 0$
- **Μονοτονία:** $\forall a, b \in [0,1], \text{ αν } a \leq b \Rightarrow c(a) \geq c(b)$
- **Συνέχεια:** c συνεχής στο $[0,1]$
- **Εναγωγή:** $\forall a \in [0,1]$ είναι $c(c(a)) = a$

Το σύννηθες συμπλήρωμα δίνεται από τη σχέση:

$$\mu_{\bar{A}}(x) = 1 - \mu_A(x)$$

2.4.3 Ασαφής Σχέσεις

Οι ασαφείς σχέσεις (fuzzy relations) είναι ασαφή σύνολα ορισμένα σε πεδία αναφοράς ανώτερης διάστασης (π.χ. $X \times X$, $X \times Y \times Z$ κλπ). Ποιοτικά, μια ασαφής σχέση R θα μπορούσε να είναι μια έκφραση της μορφής «είναι βαρύτερο από» και η οποία θα συνδέει τα στοιχεία δύο άλλων συνόλων:

$$R = \text{«}x \text{ είναι βαρύτερο από } y\text{» } x \in X, y \in Y \text{ και } R \in X \times Y$$

Οι ασαφείς σχέσεις μπορεί να εκφραστούν με αναφορά όλων των ζευγών (τιμή, βαθμός συμμετοχής), δηλαδή ζευγών της μορφής $[(x, y), \mu_R(x, y)]$. Ένας άλλος τρόπος αναπαράστασης, ιδιαίτερα χρήσιμος σε υπολογισμούς είναι σε μορφή πίνακα:

$$R = \begin{bmatrix} \mu_R(x_1, y_1) & \mu_R(x_1, y_2) & \dots & \mu_R(x_1, y_n) \\ \mu_R(x_2, y_1) & \mu_R(x_2, y_2) & \dots & \mu_R(x_2, y_n) \\ \vdots & \vdots & & \vdots \\ \mu_R(x_m, y_1) & \mu_R(x_m, y_2) & \dots & \mu_R(x_m, y_n) \end{bmatrix}$$

Οι ασαφείς σχέσεις μπορούν να συνδυαστούν μεταξύ τους μέσω της διαδικασίας της σύνθεσης (composition). Αν για παράδειγμα συνδυαστεί η ασαφής σχέση $R_1(x, y)$ ορισμένη στο $X \times Y$ με την ασαφή σχέση $R_2(y, z)$ ορισμένη στο $Y \times Z$ τότε θα προκύψει μία ασαφής σχέση $R(x, z)$ η οποία θα ορίζεται στο σύνολο $X \times Z$ και θα συσχετίζει άμεσα στοιχεία των συνόλων X και Z . Βέβαια είναι απαραίτητο να προσδιοριστεί επακριβώς η συνάρτηση συμμετοχής $\mu_R(x, z)$ της R με χρήση των συναρτήσεων συμμετοχής των R_1 και R_2 . Οι βασικές πράξεις που ορίζονται μεταξύ των ασαφών σχέσεων είναι η αντιστροφή και η σύνθεση.

Αντίστροφη σχέση της $R(X, Y)$ είναι η ασαφής σχέση $R^{-1}(Y, X)$ με τύπο $R^{-1}(y, x) = R(x, y)$ για κάθε x που ανήκει στον X και κάθε y που ανήκει στον Y . Ο πίνακας συμμετοχής που παριστάνει την R^{-1} είναι ο ανάστροφος του R .

Η **σύνθεση** είναι πολύ σημαντική διαδικασία καθώς όπως θα δούμε παρακάτω οι κανόνες της μορφής if – then αντιστοιχούν σε ασαφείς σχέσεις και το πρόβλημα της ασαφούς συλλογιστικής είναι μαθηματικά ισοδύναμο με τη σύνθεση.

Αν $R_1(x, y)$ και $R_2(y, z)$ είναι δύο ασαφείς σχέσεις ορισμένες στα σύνολα « $X \times Y$ » και « $Y \times Z$ » αντίστοιχα, τότε η σύνθεση τους δίνει μια νέα σχέση $R_1 \circ R_2$.

Η sup – t σύνθεση $R: X \times Y \rightarrow [0,1]$ δύο ασαφών σχέσεων $R_1: X \times Y \rightarrow [0,1]$ και $R_2: X \times Y \rightarrow [0,1]$ ορίζεται από την εξίσωση:

$$R(x, y) = [R_1 \circ^t R_2](x, y) = \sup_{y \in Y} [\min(R_1(x, y), R_2(y, z))]$$

Οι περισσότεροι γνωστές μέθοδοι σύνθεσης ασαφών συνόλων είναι η σύνθεση max – min και η σύνθεση max – product. Η συνάρτηση συμμετοχής για την περίπτωση της max – min σύνθεσης δίνεται από τη σχέση:

$$\mu_{R_1 \circ R_2}(x, z) = \bigvee_y [\mu_{R_1}(x, y) \wedge \mu_{R_2}(y, z)]$$

Στην περίπτωση της σύνθεσης max – product έχουμε την παρακάτω σχέση:

$$\mu_{R_1 \circ R_2}(x, z) = \bigvee_y [\mu_{R_1}(x, y) \cdot \mu_{R_2}(y, z)]$$

Οι υπολογισμοί στο δεξιό μέρος των παραπάνω σχέσεων είναι παρόμοιοι με του πολλαπλασιασμού των πινάκων [14].


2.5 Ασαφής Συλλογιστική και Ασαφείς Κανόνες

Σύμφωνα με τον Zadeh η **ασαφής συλλογιστική (Fuzzy reasoning)** είναι μια διαδικασία επίλυσης, κατά προσέγγιση, ενός συνόλου λογικών εξισώσεων που διαχειρίζονται τη μη μοναδικότητα των ασαφών υποθέσεων. Αποτελεί μια μεθοδολογία εξόδου συμπερασμάτων βασισμένη σε ένα σύνολο ασαφών κανόνων. Σε αντίθεση με την κλασσική συλλογιστική, η ασαφής συλλογιστική χρησιμοποιεί λεκτικές μεταβλητές.

Αυτές οι λεκτικές μεταβλητές αποτελούν τον **ασαφή κανόνα** ο οποίος είναι μία, υπό συνθήκη, έκφραση που σχετίζει δύο ή περισσότερες ασαφείς προτάσεις. Στην απλούστερη μορφή του, ο ασαφής κανόνας αποτελείται από το τμήμα **if της υπόθεσης (premise part)** και το τμήμα **then της απόδοσης (consequence part)**.

Η ασαφής λογική ασχολείται με την παραγωγή συλλογιστικής σε περιβάλλον αβεβαιότητας αλλά όχι τυχαιότητας. Για να επιτευχθεί αυτό, απαιτείται η δημιουργία μιας δομής και μιας μαθηματικής αναπαράστασης ενός ασαφούς γεγονότος, ορίζοντας τα ασαφή σύνολα. Στη συνέχεια έχουμε τον συνδυασμό των γεγονότων με σκοπό να παράγουμε λογικές προτάσεις ή σχέσεις και να φτάσουμε στα τελικά συμπεράσματα.

Η διαδικασία της ασαφούς συλλογιστικής περιλαμβάνει τα ακόλουθα στάδια [15]:



Σχήμα 2.3 Διαδικασία Ασαφούς Συλλογιστικής

Ο ασαφής κανόνας είναι μία μορφή γνώσης με έναν τρόπο που αντανακλά τον ανθρώπινο τρόπο σκέψης. Η περιγραφή ασαφών συνόλων με λεκτικούς όρους και ο συνδυασμός αυτών παράγει ασαφείς κανόνες, οι οποίοι αναπαριστούν τη γνώση μας για το σύστημα.

Ένας απλός ασαφής κανόνας ικανοποιεί την συνθήκη:

if x is A then y is B

όπου A και B είναι οι γλωσσικές μεταβλητές που προσδιορίζονται από ασαφή σύνολα με χώρο μεταφοράς X και Y αντίστοιχα. Το μέρος «if x is A» αποτελεί την υπόθεση και το μέρος «then y is B» εκφράζει την απόφαση ή το συμπέρασμα.

Παράδειγμα κανόνα if – then

if service is good then tip is average

Η λέξη «good» αντιστοιχεί σε έναν αριθμό που κυμαίνεται μεταξύ 0 και 1. Συνεπώς, η υπόθεση είναι μια έκφραση που επιστρέφει μια τιμή από το 0 έως το 1. Αντιθέτως, η λέξη «average» αποτελεί ένα ασαφές σύνολο και έτσι η συνέπεια του κανόνα είναι μια συσχέτιση της εξόδου y στο ασαφές σύνολο B.

Στους κανόνες if – then η λέξη «is» έχει διαφορετική έννοια ανάλογα με το αν εμφανίζεται στο πρώτο ή στο δεύτερο μέρος του κανόνα. Έτσι όταν εμφανίζεται στο πρώτο μέρος του κανόνα έχει την έννοια του ελέγχου ισότητας (δηλαδή την ίδια έννοια που δίνουμε στο σύμβολο ==). Αντίθετα όταν εμφανίζεται στο δεύτερο μέρος του κανόνα έχει την έννοια της καταχώρησης (δηλαδή την έννοια που δίνουμε στο σύμβολο =). Ο παραπάνω κανόνας λοιπόν θα μπορούσε να γραφεί συμβολικά και ως εξής:

if service == good then tip = average

Γενικά η είσοδος σε έναν κανόνα if – then είναι η τρέχουσα τιμή της μεταβλητής εισόδου ενώ η έξοδος του κανόνα είναι ολόκληρο το ασαφές σύνολο. Από αυτό όμως το ασαφές σύνολο θα πρέπει να κρατήσουμε μια τιμή έτσι ώστε να μπορούμε να βγάλουμε κάποια συμπεράσματα. Γι' αυτό πρέπει να

γίνει μια διαδικασία που ονομάζεται **αποασαφοποίηση (defuzzification)**. Για να διερμηνεύσουμε έναν κανόνα if – then πρέπει να ακολουθήσουμε κάποια στάδια. Αρχικά πρέπει να υπολογίσουμε την είσοδο. Για να γίνει αυτό όμως πρέπει να γίνει **ασαφοποίηση (fuzzyfication)** της εισόδου και να εφαρμοσθούν οι κατάλληλοι ασαφείς τελεστές. Κατόπιν πρέπει να εφαρμόσουμε το παραπάνω αποτέλεσμα στο δεύτερο μέρος του κανόνα.

Στην απλή περίπτωση των δυαδικών τιμών οι κανόνες if – then είναι αρκετά εύκολο να εφαρμοσθούν. Αν η προϋπόθεση είναι αληθής τότε και η συνέπεια θα είναι αληθής. Πώς όμως επεκτείνεται η παραπάνω συλλογιστική για να συμπεριλάβει και ασαφείς τιμές; Όταν η προϋπόθεση είναι αληθής σε κάποιο βαθμό τότε και η συνέπεια είναι αληθής στον ίδιο βαθμό.

Με άλλα λόγια:

- **Στη δυαδική λογική: $p \rightarrow q$** (Τα p και q είναι και τα δύο είτε πλήρως αληθή ή πλήρως ψευδή)
- **Στην ασαφή λογική: $0.5p \rightarrow 0.5q$** (Τα p και q είναι μερικώς αληθή και μερικώς ψευδή)

Η προϋπόθεση ενός κανόνα μπορεί να αποτελείται από περισσότερα του ενός μέρη. Όπως για παράδειγμα ο παρακάτω κανόνας:

if sky is gray and wind is strong and barometer is falling, then ...

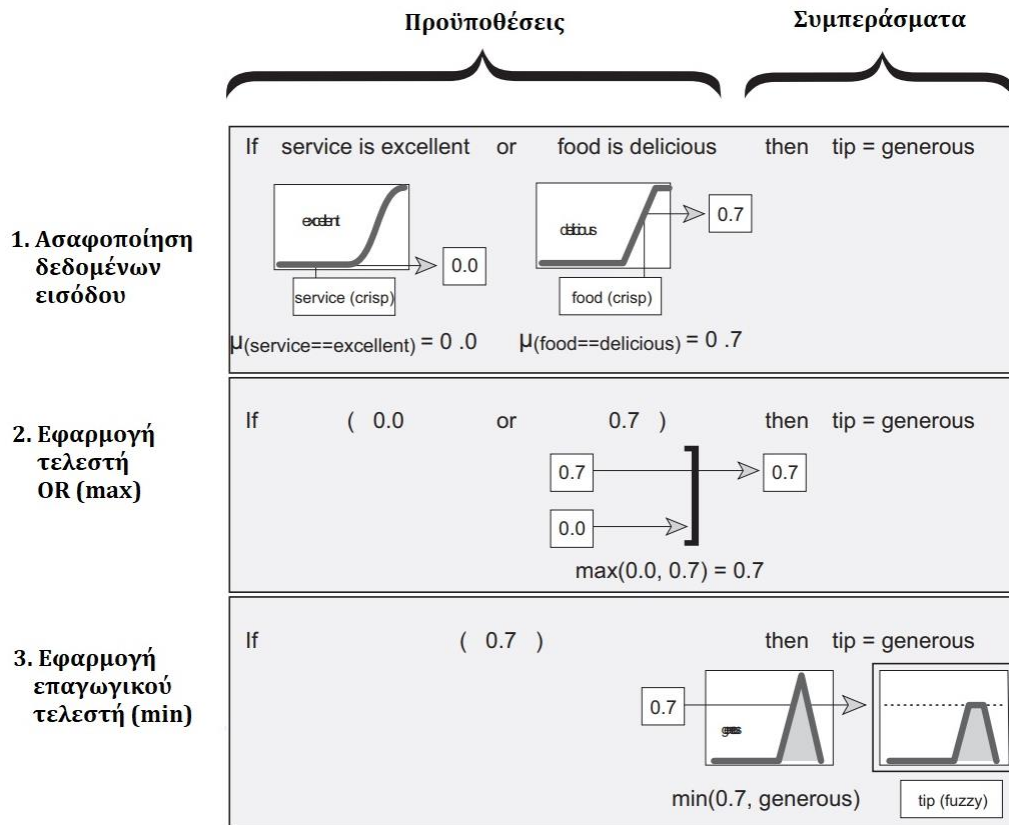
Σ' αυτή την περίπτωση όλα τα μέρη της προϋπόθεσης υπολογίζονται ταυτόχρονα και καταλήγουμε σε ένα μοναδικό νούμερο ανάλογα με τους λογικούς τελεστές που χρησιμοποιούμε.

Αλλά και η συνέπεια ενός κανόνα μπορεί να αποτελείται από περισσότερα του ενός μέρη. Για παράδειγμα ο παρακάτω κανόνας:

if temperature is cold then hot water valve is open and cold water valve is shut

Όλα τα μέρη της συνέπειας του κανόνα επηρεάζονται το ίδιο από το αποτέλεσμα της προϋπόθεσης. Η συνέπεια του κανόνα προσδιορίζει ένα ασαφές σύνολο το οποίο συσχετίζεται με την έξοδο. Η **συνάρτηση συνεπαγωγής (implication function)** στη συνέχεια τροποποιεί το ασαφές σύνολο στο βαθμό που προσδιορίζεται από την προϋπόθεση του κανόνα.

Μια πολύ συνηθισμένη συνάρτηση για να γίνει αυτό είναι η αποκοπή με τη χρήση του τελεστή min. Στο παρακάτω σχήμα βλέπουμε τον τρόπο με τον οποίο εφαρμόζονται οι κανόνες if – then.

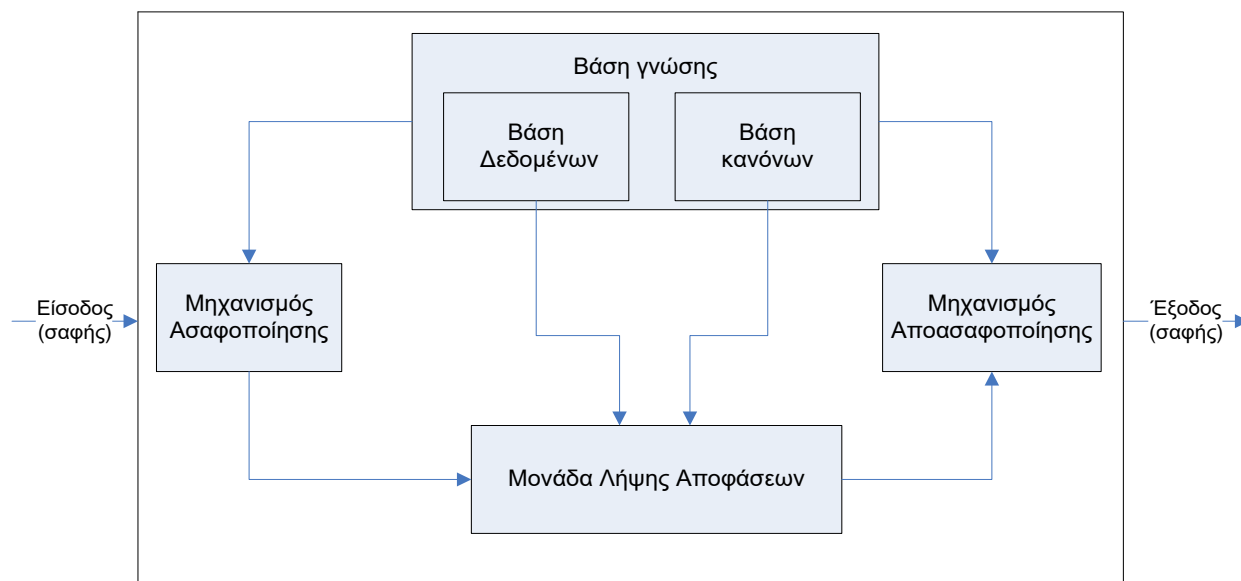


Σχήμα 2.4 Κανόνες if – then στην Ασαφή Λογική

Γενικά ένας κανόνας από μόνος του δεν επαρκεί για τα περισσότερα πρακτικά προβλήματα. Αυτό που χρειαζόμαστε είναι, περισσότεροι του ενός, κανόνες οι οποίοι να αλληλεπιδρούν μεταξύ τους. Η έξοδος κάθε κανόνα θα είναι ένα ασαφές σύνολο. Τα ασαφή σύνολα που προκύπτουν σαν συνέπεια των κανόνων συγκεντρώνονται για να σχηματίσουν ένα ασαφές σύνολο εξόδου από το οποίο μέσω της διαδικασίας της αποσαφήνισης θα πάρουμε μια μοναδική τιμή[16].

2.6 Ασαφής Συστήματα Συμπερασμού (Fuzzy Inference Systems – FIS)

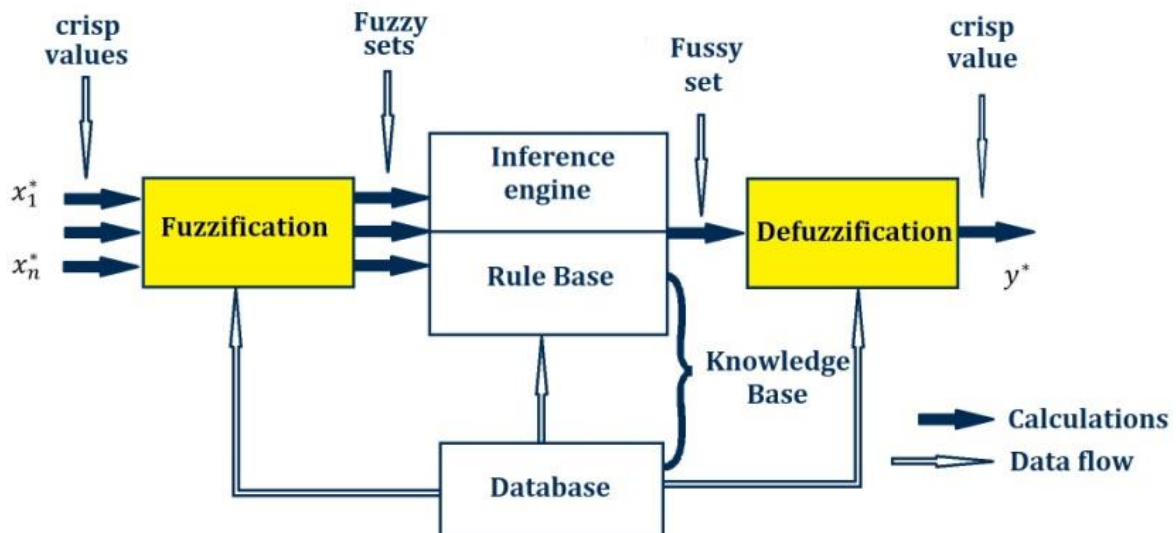
Ένα ασαφές σύστημα συμπερασμού είναι μια δομή υπολογισμού που βασίζεται στη θεωρία των ασαφών συνόλων, στους ασαφείς κανόνες if – then και στην ασαφή συλλογιστική [12].



Σχήμα 2.5 Δομή Ασαφούς Συστήματος Συμπερασμού

Ένα ασαφές σύστημα συμπερασμού αποτελείται από:

1. **Την Βάση Γνώσης (Knowledge Base)**, που αποτελείται από την **Βάση Κανόνων (Rule Base)** και την **Βάση Δεδομένων (Database)**. Η βάση κανόνων περιέχει την κωδικοποίηση ενός αριθμού ασαφών κανόνων (fuzzy rules) της μορφής «if – then». Η βάση δεδομένων ορίζει τις συναρτήσεις συμμετοχής (membership functions) των ασαφών συνόλων που χρησιμοποιούνται στους ασαφείς κανόνες.
2. **Τη Μονάδα Λήψης Αποφάσεων (Decision Making Unit)**, η οποία χρησιμοποιεί τους κανόνες και τις συναρτήσεις συμμετοχής, προκειμένου να υλοποιήσει ευέλικτα τη λειτουργία της εξαγωγής συμπερασμάτων.
3. **Το Μηχανισμό Ασαφοποίησης (Fuzzyfication Inference)**, ο οποίος μετασχηματίζει τα δεδομένα εισόδου σε βαθμούς συγγένειας με τιμές λεκτικών μεταβλητών (linguistic variables).
4. **Το Μηχανισμό Αποασαφοποίησης (Defuzzyfication Inference)**, ο οποίος μετασχηματίζει τα ασαφή σύνολα (fuzzy sets) που επιστρέφονται σαν αποτελέσματα του μηχανισμού επεξεργασίας σε τιμές εξόδου, βαθμωτές (scalar) ή διανυσματικές (vector).



Σχήμα 2.6 Δομή Ασαφούς Συστήματος Συμπερασμού

Οι δύο πιο γνωστοί τύποι ασαφών συστημάτων συμπερασμού είναι οι ακόλουθοι:

- **Ασαφές σύστημα συμπερασμού Takagi - Sugeno - Kang (TSK)** (Takami and Sugeno, 1985), (Sugeno and Kang, 1988) όπου η έξοδος των κανόνων είναι πραγματική τιμή.
- **Ασαφές σύστημα συμπερασμού Mamdani** (Ebrahim Mamdani, 1975) όπου η έξοδος των κανόνων είναι ασαφείς τιμές που πρέπει να συνδυαστούν.

Πλεονεκτήματα της μεθόδου Takagi - Sugeno - Kang (TSK)

- Είναι υπολογιστικά αποδοτική
- Λειτουργεί καλά με γραμμικές τεχνικές (π.χ. έλεγχος PID).
- Λειτουργεί καλά με τεχνικές βελτιστοποίησης και προσαρμογής
- Εξασφαλίζει συνέχεια στην επιφάνεια εξόδου
- Είναι κατάλληλη για μαθηματική ανάλυση

Πλεονεκτήματα της μεθόδου Mamdani

- Είναι ευανάγνωστη και κατανοητή
- Έχει ευρεία αποδοχή
- Είναι καλά προσαρμοσμένη στην ανθρώπινη καταχώρηση

Στο παρόν ερευνητικό έργο γίνεται χρήση του συστήματος **TSK** το οποίο παρουσιάζεται αναλυτικά στη επόμενη υποενότητα.

2.7 Ασαφές Σύστημα Συμπερασμού Takagi – Sugeno – Kang (TSK)

Το ασαφές μοντέλο Sugeno δημιουργήθηκε σε μια προσπάθεια να αναπτυχθεί μια συστηματική προσέγγιση στη γέννηση ασαφών κανόνων από ένα δεδομένο σύνολο δεδομένων εισόδου-εξόδου. Σε πολλές περιπτώσεις είναι περισσότερο αποτελεσματική η χρήση σημείων – αιχμών σαν συναρτήσεις συμμετοχής εξόδου, από ένα συνεχές καταναμημένο ασαφές σύνολο. Μια τέτοια αιχμή είναι γνωστή με τον αγγλικό όρο **συνάρτηση συμμετοχής εξόδου singleton** και θα μπορούσε να χαρακτηριστεί σαν προαποσαφοποιημένο ασαφές σύνολο. Η συνάρτηση συμμετοχής ενός singleton είναι $\mu A(x) = 1$.

Με αυτόν τον τρόπο εμπλουτίζουμε την επάρκεια της διαδικασίας αποσαφοποίησης, διότι απλοποιούμε ιδιαιτέρως τους απαιτούμενους υπολογισμούς σε σχέση με την πιο γενική μέθοδο Mamdani, στην οποία βρίσκουμε το κέντρο μάζας μια δισδιάστατης συνάρτησης. Αντί λοιπόν να βρίσκουμε το κέντρο μάζας, χρησιμοποιούμε τον σταθμικό μέσο μερικών σημείων. Τα συστήματα τύπου Sugeno υποστηρίζουν αυτόν τον τύπο μοντέλου.

Η λεγόμενη μέθοδος Sugeno, ή Takagi – Sugeno – Kang, ασαφούς συμπερασμάτων, εισήχθη το 1985 [17] και είναι παρόμοια με τη μέθοδο Mamdani από πολλές απόψεις. Τα δύο πρώτα μέρη της διαδικασίας ασαφούς συμπερασμάτων, η ασάφεια των εισόδων και η εφαρμογή του ασαφούς τελεστή, είναι ακριβώς τα ίδια. Η κύρια διαφορά μεταξύ Mamdani και Sugeno είναι ότι **οι συναρτήσεις μέλους Sugeno output είναι είτε γραμμικές είτε σταθερές**.

Ένας τυπικός κανόνας σε ένα ασαφές μοντέλο Sugeno έχει τη μορφή:

$$\text{If } x = A \text{ and } y = B, \text{ then } z = f(x, y)$$

όπου τα A και B είναι τα ασαφή σύνολα των εισόδων και η $f(x, y)$ μία σαφής συνάρτηση των μεταβλητών εισόδου x και y , συνήθως πολυώνυμο, αλλά μπορεί να είναι μια οποιαδήποτε συνάρτηση, αρκεί να μπορεί να περιγράψει κατάλληλα την έξοδο του μοντέλου, μέσα στην ασαφή περιοχή που ορίστηκε από τις προϋποθέσεις των κανόνων. Όταν το $f(x, y)$ είναι πολυώνυμο πρώτου βαθμού το FIS ονομάζεται ασαφές μοντέλο πρώτου βαθμού.

Ένα σύστημα Sugeno πρώτης τάξης θα έχει κανόνες με τη γενική μορφή

$$\text{If } x = A \text{ and } y = B, \text{ then } z = p * x + q * y + r$$

όπου A και B είναι οι τιμές συμμετοχής των εισερχόμενων μεταβλητών x και y .
ενώ τα p, q, r είναι παράμετροι των συναρτήσεων f .

Για παράδειγμα:


If $input - 1 = x$ **and** $input - 2 = y$, **then** $Output$ is $z = ax + by + c$

Για ένα Sugeno μηδενικού βαθμού το επίπεδο εξόδου z είναι μια σταθερά ($a = b = 0$) και μπορεί να θεωρηθεί και σαν μια ειδική περίπτωση Mamdani, στο οποίο το συμπέρασμα του κάθε κανόνα προσδιορίζεται από ένα ασαφές singleton (προαποσαφολοποιημένο συμπέρασμα). Η έξοδος ενός Sugeno μηδενικού βαθμού είναι ομαλή μια συνάρτηση των μεταβλητών εισόδων του, εφόσον οι γειτονικές συναρτήσεις συμμετοχής στις προϋποθέσεις έχουν αρκετή επικάλυψη.

Στο παρακάτω σχήμα βλέπουμε ότι το επίπεδο εξόδου Z_i για κάθε κανόνα είναι σταθμισμένο με βάρη ή αλλιώς με μια δύναμη πυροδότησης (βαθμός ενεργοποίησης) w_i για κάθε κανόνα. Για παράδειγμα για τον τελεστή AND, με είσοδο $-1 = x$ και είσοδο $-2 = y$, η δύναμη πυροδότησης είναι:

$$w_i = AND(F1(x), F2(x))$$

όπου $F1$ και $F2$ είναι οι συναρτήσεις συμμετοχής για τις αντίστοιχες εισόδους.




Σχήμα 2.7 Ασαφές Μοντέλο Sugeno Πρώτου Βαθμού

Η τελική έξοδος του συστήματος είναι ο σταθμισμένος μέσος όλων των εξόδων και δίνεται από τον τύπο:

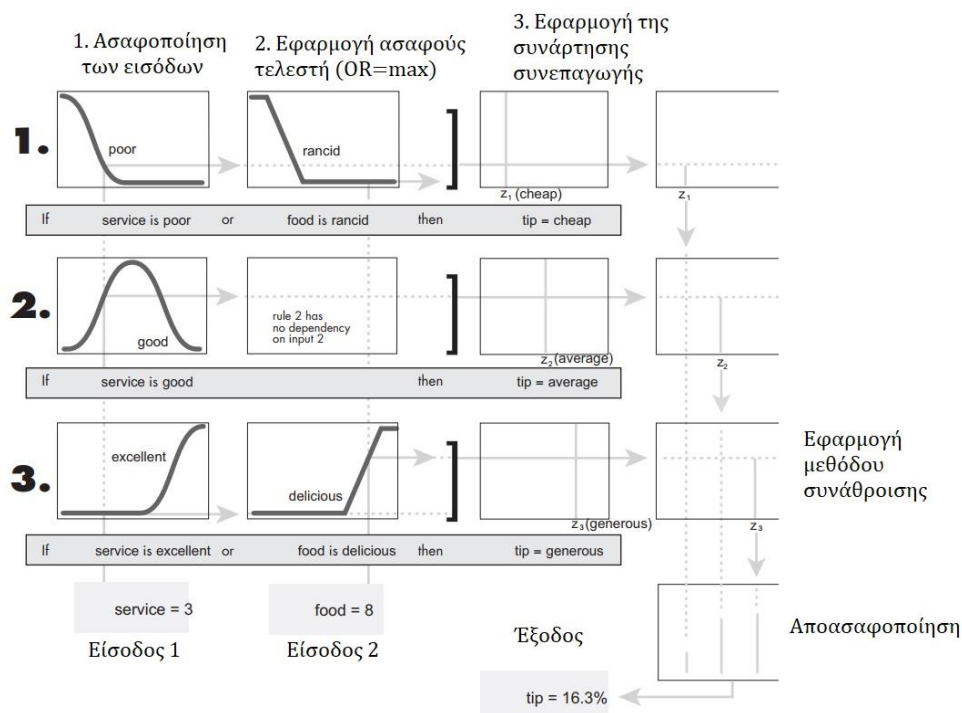
$$Τελική\ έξοδος = \frac{\sum_{i=1}^N w_i z_i}{\sum_{i=1}^N w_i}$$

Στο παρακάτω σχήμα φαίνεται η λειτουργία του Sugeno για το παράδειγμα που αναφέραμε.



Σχήμα 2.8 Ασαφές Μοντέλο Sugeno, Δύναμη Πυροδότησης


Στα σχήματα που ακολουθούν παρακάτω φαίνεται σε πλήρη ανάπτυξη το FIS Sugeno για το πρόβλημα με το ποσοστό του φιλοδωρήματος, όπου η χρήση των συναρτήσεων singleton είναι απολύτως επαρκής.



Σχήμα 2.9 Ασαφές Σύστημα Συμπερασμού Takagi – Sugeno – Kang (TSK) Ποσοστό Φιλοδωρήματος

Ο πιο εύκολος τρόπος να κατανοήσουμε τα ασαφή συστήματα Sugeno πρώτου βαθμού, είναι να σκεφτούμε πως ο κάθε κανόνας προσδιορίζει τη θέση ενός «κινούμενου singleton». Οι αιχμές δηλαδή των singleton της εξόδου

μπορούν να κινηθούν με γραμμικό τρόπο στο χώρο εξόδου, ανάλογα με τις εισόδους.



Σχήμα 2.10 Επιφάνεια της Λύσης του Προβλήματος Φιλωδότημα

Συστήματα Sugeno ανώτερης τάξης είναι εφικτά, όμως δεν προσφέρουν σημαντικές βελτιώσεις και ταυτόχρονα εισαγάγουν σημαντική πολυπλοκότητα [11].

3^ο ΚΕΦΑΛΑΙΟ



ΝΕΥΡΩΝΙΚΑ
ΔΙΚΤΥΑ

ΚΕΦΑΛΑΙΟ 3ο – ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ

3.1 Εισαγωγή στα Νευρωνικά Δίκτυα

Η επιστήμη της τεχνητής νοημοσύνης παρουσιάζει ιδιαίτερη ανάπτυξη τα τελευταία 20 χρόνια, χάρη στην προσπάθεια της επιστημονικής κοινότητας να προσομοιάσει τον τρόπο λειτουργίας του ανθρώπινου εγκεφάλου. Ένα από τα βασικά εργαλεία της είναι τα **Τεχνητά Νευρωνικά Δίκτυα – ΤΝΔ (Artificial Neural Networks – ANN)**, τα οποία προσεγγίζουν τη λειτουργία των βιολογικών νευρωνικών δικτύων. Η ανάπτυξη των τεχνητών νευρωνικών δικτύων ξεκίνησε πριν από περίπου 70 χρόνια, έχοντας ως κίνητρα την επιθυμία κατανόησης της λειτουργίας του ανθρώπινου εγκεφάλου και τη μίμηση των δυνατοτήτων του. Με τη συνεχή ανάπτυξη των υπολογιστικών δυνατοτήτων των Η/Υ, οι επιστήμονες προσπάθησαν να χρησιμοποιήσουν αυτή την τεχνογνωσία για την αντιμετώπιση, σχετικά απλών για την ανθρώπινη νοημοσύνη, προβλημάτων.

Ο ανθρώπινος εγκέφαλος μπορεί να μην έχει τη δυνατότητα επίλυσης πολύπλοκων μαθηματικών πράξεων με ταχύτητα όση ενός Η/Υ, έχει όμως την ικανότητα επεξεργασίας πληροφοριών με βάση την εμπειρία που διαθέτει. Η ανθρώπινη μνήμη έχει την ικανότητα αποθήκευσης μεγάλου αριθμού πληροφοριών αλλά και συσχέτισης αυτών με τρόπο γρήγορο και αποτελεσματικό. Εν αντιθέσει, οι σύγχρονοι Η/Υ ενώ έχουν την ικανότητα αποθήκευσης μεγάλου όγκου δεδομένων, δεν έχουν την δυνατότητα συσχέτισης και εκμετάλλευσης αυτών των πληροφοριών.

3.2 Βιολογικός Νευρώνας

Όπως προαναφέρθηκε, ο ανθρώπινος εγκέφαλος συγκριτικά με τον Η/Υ, χρησιμοποιεί μια αρχιτεκτονική που είναι καταλληλότερη να αντιμετωπίσει την φυσική επεξεργασία πληροφοριών γνωστή και ως δομή μαζικού παραλληλισμού (massively parallel) ή παράλληλης κατανεμημένης επεξεργασίας (parallel distributed).


Ο ανθρώπινος εγκέφαλος αποτελείται από περίπου εκατό δισεκατομμύρια κύτταρα, τους γνωστούς «νευρώνες». Στην παρακάτω Εικόνα 3.1, βλέπουμε τα κύρια μέρη ενός νευρώνα σε μια απλή τυπική δομή.

Δενδρίτες (Dendrites): Δέχονται τα εισερχόμενα ηλεκτρικά σήματα μέσω των συνάψεων με άλλους νευρώνες και τα προωθούν στο κυτταρικό σώμα.

Κυτταρικό Σώμα (Soma ή Cell Body): Υπεύθυνο για την επεξεργασία των εισερχόμενων σημάτων από τους δενδρίτες και την παραγωγή άλλων σημάτων τα οποία μεταφέρονται σε άλλα γειτονικά κύτταρα μέσω του άξονα.

Άξονας (Axon): Είναι ακριβώς όπως ένα καλώδιο μέσω του οποίου στέλνονται πληροφορίες από το κυτταρικό σώμα σε άλλους νευρώνες.

Συνάψεις (Synapse): Είναι η σύνδεση μεταξύ του άξονα και άλλων δενδριτών του νευρώνα [18].



Εικόνα 3.1 Δομή Βιολογικού Νευρώνα

Οι συνάψεις μέσω χημικών διαδικασιών επιταχύνουν ή επιβραδύνουν τη ροή ηλεκτρονίων προς το σώμα του νευρώνα. Η ικανότητα μάθησης μνήμης που παρουσιάζει ο εγκέφαλος οφείλεται στην ικανότητά των συνάψεων να μεταβάλλουν την αγωγιμότητά τους. Τα ηλεκτρικά σήματα που εισέρχονται στο σώμα του νευρώνα μέσω των δενδριτών, συνδυάζονται και αν το αποτέλεσμα ξεπερνά κάποια τιμή κατωφλίου τότε, με τη βοήθεια του άξονα, διαδίδεται το σήμα και στους άλλους νευρώνες. Η διαδικασία μετάδοσης γίνεται με τη διάχυση χημικών ουσιών που ονομάζονται νευροδιαβιβαστές κατά μήκος της συναπτικής σχισμής [16].

3.3 Τεχνητά Νευρωνικά Δίκτυα - ΤΝΔ

3.3.1 Ορισμός – Χαρακτηριστικά – Κατηγοριοποιήσεις ΤΝΔ

Σύμφωνα με την L. Fausett, τα Τεχνητά Νευρωνικά Δίκτυα ΤΝΔ (Artificial Neural Networks - ANN) είναι συστήματα επεξεργασίας πληροφοριών που έχουν ορισμένα κοινά χαρακτηριστικά απόδοσης με τα βιολογικά νευρωνικά δίκτυα. Κάποια βασικά χαρακτηριστικά των στοιχείων επεξεργασίας (processing elements) των ΤΝΔ προτείνονται από τις ιδιότητες των βιολογικών νευρώνων, δηλαδή ότι:

1. Το στοιχείο επεξεργασίας λαμβάνει πολλά σήματα.
2. Τα σήματα μπορούν να τροποποιηθούν από ένα βάρος στη σύναψη λήψης.
3. Το στοιχείο επεξεργασίας αθροίζει τις σταθμισμένες εισροές.
4. Υπό κατάλληλες συνθήκες (επαρκής είσοδος), ο νευρώνας εκπέμπει μία μόνο έξοδο.
5. Η έξοδος από έναν συγκεκριμένο νευρώνα μπορεί να πάει σε πολλούς άλλους νευρώνες (τους κλάδους του άξονα).
6. Η επεξεργασία των πληροφοριών είναι τοπική
7. Η μνήμη κατανέμεται:
 - i. Η μακροπρόθεσμη μνήμη βρίσκεται στις συνάψεις ή τα βάρη των νευρώνων.
 - ii. Η βραχυπρόθεσμη μνήμη αντιστοιχεί στα σήματα που στέλνουν οι νευρώνες.
8. Η ισχύς μιας σύναψης μπορεί να τροποποιηθεί από την εμπειρία.
9. Οι νευροδιαβιβαστές για τις συνάψεις μπορεί να είναι διεγερτικοί ή ανασταλτικοί.
10. Ένα τελευταίο σημαντικό χαρακτηριστικό που μοιράζονται τα τεχνητά νευρωνικά δίκτυα με τα βιολογικά νευρωνικά συστήματα είναι η ανοχή σε σφάλματα.

Μπορούμε να διαχωρίσουμε τα ΤΝΔ σε δύο βασικές κατηγορίες, βάσει των στοιχείων που τα απαρτίζουν:

1. Στα **Στατικά Νευρωνικά Δίκτυα**, τα οποία δεν περιέχουν στοιχεία μνήμης αλλά μπορούν να έχουν ως εισόδους προηγούμενες τιμές των εισόδων και
2. Στα **Δυναμικά Νευρωνικά Δίκτυα**, τα οποία διαθέτουν στοιχεία μνήμης και είναι κατάλληλα για την προτυποποίηση μη γραμμικών δυναμικών συστημάτων.

Τα ΤΝΔ έχουν αναπτυχθεί ως γενικεύσεις μαθηματικών μοντέλων ανθρώπινης γνώσης ή νευρωνικής βιολογίας, με βάση τις παρακάτω υποθέσεις:

1. Η επεξεργασία πληροφοριών λαμβάνει χώρα σε πολλά απλά στοιχεία που ονομάζονται **νευρώνες**.
2. Τα σήματα περνούν μεταξύ των νευρώνων μέσω **συνδέσμων σύνδεσης**.
3. Κάθε σύνδεσμος σύνδεσης έχει ένα **σχετικό βάρος**, το οποίο, σε ένα τυπικό νευρωνικό δίκτυο, πολλαπλασιάζει το μεταδιδόμενο σήμα.
4. Κάθε νευρώνας εφαρμόζει μια **συνάρτηση ενεργοποίησης** ή αλλιώς **συνάρτηση μεταφοράς**, οποία είναι συνήθως μη γραμμική, στην καθαρή του

είσοδο (άθροισμα σταθμισμένων σημάτων εισόδου) για να καθορίσει το σήμα εξόδου του.

Όπως προαναφέρθηκε η επεξεργασία λαμβάνει χώρα σε πολλά απλά στοιχεία, τους νευρώνες, οι οποίοι είναι αλληλοσυνδεδεμένοι ώστε να έχουν την ικανότητα ταυτόχρονης επεξεργασίας των πληροφοριών. Οι νευρώνες αποτελούν δομικά στοιχεία του δικτύου και χωρίζονται σε δύο κατηγορίες: α) τους **νευρώνες εισόδου**. Κάθε νευρώνας μπορεί να έχει πολλές εισόδους αλλά μονό μια έξοδο η οποία αποτελεί είσοδο αλλού νευρώνα και β) τους **υπολογιστικούς νευρώνες**. Οι νευρώνες εισόδου δεν υπολογίζουν τίποτα, απλώς μεσολαβούν ανάμεσα στις εισόδους του δικτύου και τους υπολογιστικούς νευρώνες. Οι υπολογιστικοί νευρώνες πολλαπλασιάζουν τις εισόδους τους με τα σχετικά βάρη και υπολογίζουν το άθροισμα του γινομένου. Το άθροισμα που προκύπτει είναι το όρισμα της συνάρτησης μεταφοράς η οποία καθορίζει την κάθε έξοδο με βάση τις εισόδους και του συντελεστής βάρους.

Τα στοιχεία που χαρακτηρίζουν κάθε ΤΝΔ είναι:


1. **η αρχιτεκτονική** του ΤΝΔ, δηλαδή το μοτίβο των συνδέσεων του μεταξύ των νευρώνων
2. **ο αλγόριθμος εκπαίδευσης ή εκμάθησης**, που αποτελεί την μέθοδο προσδιορισμού των βαρών στις συνδέσεις δηλαδή και
3. **η συνάρτηση μεταφοράς**, η οποία μπορεί να είναι μία βηματική συνάρτηση, μία γραμμική συνάρτηση ή μία συνεχής μη γραμμική συνάρτηση.

Τα νευρωνικά δίκτυα μπορούν να εφαρμοστούν σε μια μεγάλη ποικιλία προβλημάτων, όπως αποθήκευση και ανάκληση δεδομένων ή μοτίβων, ταξινόμηση μοτίβων, εκτέλεση γενικών αντιστοιχίσεων από μοτίβα εισόδου σε μοτίβα εξόδου, ομαδοποίηση παρόμοιων προτύπων ή εύρεση λύσεων σε προβλήματα περιορισμένης βελτιστοποίησης.

Κάθε νευρώνας έχει μια εσωτερική κατάσταση, που ονομάζεται **επίπεδο ενεργοποίησης ή δραστηριότητας**, η οποία είναι συνάρτηση των εισόδων που έχει λάβει. Τυπικά, ένας νευρώνας στέλνει την ενεργοποίησή του ως σήμα σε αρκετούς άλλους νευρώνες. Είναι σημαντικό να σημειωθεί ότι ένας νευρώνας μπορεί να στείλει μόνο ένα σήμα τη φορά, αν και αυτό το σήμα μεταδίδεται σε πολλούς άλλους νευρώνες. Για παράδειγμα, θεωρήστε έναν νευρώνα Y , που απεικονίζεται στο παρακάτω Σχήμα 3.1, που λαμβάνει εισόδους από τους

νευρώνες X_1 , X_2 και X_3 . Οι ενεργοποιήσεις (σήματα εξόδου) αυτών των νευρώνων είναι x_1 , x_2 και x_3 , αντίστοιχα. Τα βάρη στις συνδέσεις από τα X_1 , X_2 και X_3 στον νευρώνα Y είναι w_1 , w_2 και w_3 , αντίστοιχα. Η καθαρή είσοδος, y_{in} , στον νευρώνα Y είναι το άθροισμα των σταθμισμένων σημάτων από τους νευρώνες X_1 , X_2 και X_3 , δηλαδή

$$y_{in} = w_1x_1 + w_2x_2 + w_3x_3$$



Σχήμα 3.1 Απλός Τεχνητός Νευρώνας

Η ενεργοποίηση y του νευρώνα Y δίνεται από ορισμένη συνάρτηση της καθαρής εισόδου του, $y = f(y_{in})$, για παράδειγμα, η λογιστική σιγμοειδής συνάρτηση (μια καμπύλη σε σχήμα S)

$$f(x) = \frac{1}{1 + e^{-x}}$$

ή οποιαδήποτε από μια σειρά από άλλες συναρτήσεις ενεργοποίησης, που θα δούμε σε επόμενη υποενότητα.


Συνοψίζοντας, εάν x_{ki} είναι η i -οστή είσοδος του k νευρώνα, w_{ki} το i -οστό συνοπτικό βάρος του k νευρώνα και $\varphi(\cdot)$ η συνάρτηση μεταφοράς του νευρωνικού δικτύου, τότε η έξοδος y_k του k νευρώνα δίνεται από την εξίσωση:

$$y_k = \varphi \left(\sum_{i=0}^N x_{ki} w_{ki} \right)$$

Στον k -οστό νευρώνα υπάρχει ένα συνοπτικό βάρος w_{k0} με ιδιαίτερη σημασία, το οποίο καλείται πόλωση ή κατώφλι (bias, threshold). Η τιμή της εισόδου του είναι πάντα η μονάδα, $x_{k0} = 1$. Εάν το συνολικό άθροισμα από τις υπόλοιπες εισόδους του νευρώνα είναι μεγαλύτερο από την τιμή αυτή, τότε ο νευρώνας ενεργοποιείται. Εάν είναι μικρότερο, τότε ο νευρώνας παραμένει ανενεργός. Η ιδέα προέκυψε από τα βιολογικά νευρικά κύτταρα.

Υποθέτουμε ότι ο νευρώνας Y είναι συνδεδεμένος με τους νευρώνες Z_1 και Z_2 , με βάρη v_1 και v_2 , αντίστοιχα, όπως φαίνεται στο Σχήμα 3.2. Ο νευρώνας Y στέλνει το σήμα του y σε καθεμία από αυτές τις μονάδες.

Ωστόσο, γενικά, οι τιμές που λαμβάνονται από τους νευρώνες Z_1 και Z_2 θα είναι διαφορετικές, επειδή κάθε σήμα κλιμακώνεται με το κατάλληλο βάρος, v_1 ή v_2 . Σε ένα τυπικό δίκτυο, οι ενεργοποιήσεις z_1 και z_2 των νευρώνων Z_1 και Z_2 θα εξαρτώνται από εισόδους από αρκετούς ή και πολλούς νευρώνες, όχι μόνο από έναν, όπως φαίνεται σε αυτό το απλό παράδειγμα.

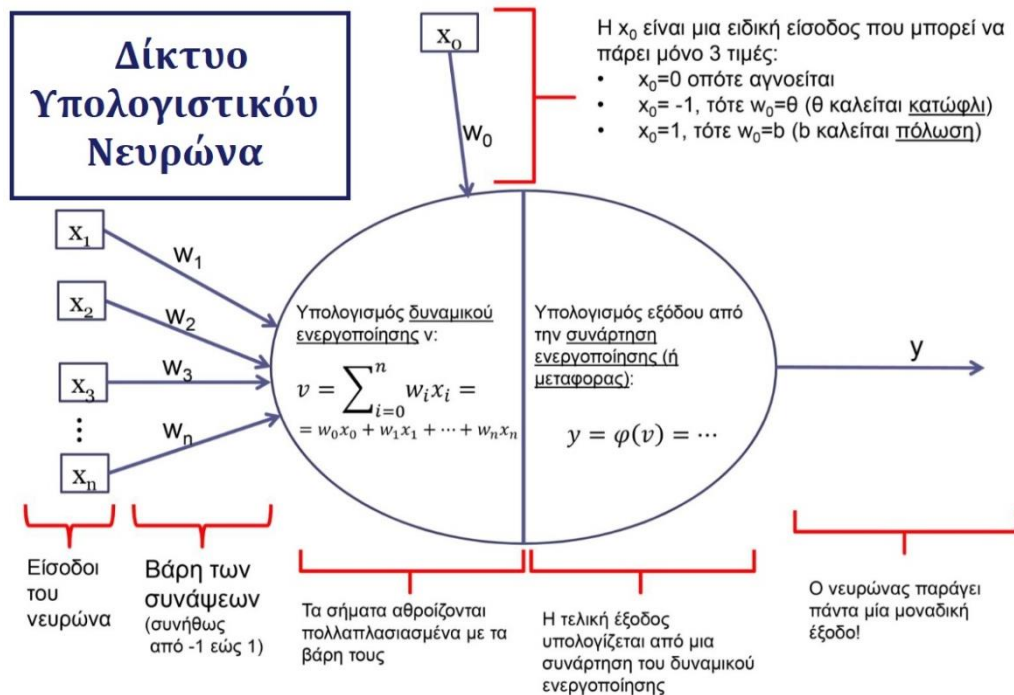


Σχήμα 3.2 Απλό Νευρωνικό Δίκτυο

Αν και το νευρωνικό δίκτυο στο Σχήμα 3.2 είναι πολύ απλό, η παρουσία μιας κρυφής μονάδας, μαζί με μια μη γραμμική συνάρτηση ενεργοποίησης, του δίνει τη δυνατότητα να λύσει πολλά περισσότερα προβλήματα από αυτά που μπορούν να λυθούν από ένα δίκτυο μόνο με μονάδες εισόδου και εξόδου. Από την άλλη πλευρά, ένα δίκτυο με κρυφές μονάδες είναι πιο δύσκολο να εκπαιδευτεί, δηλαδή να βρεθούν τις βέλτιστες τιμές για τα βάρη [19].

Όπως προαναφέρθηκε, ένα ΤΝΔ καθορίζεται από τον τύπο ή τους τύπους των νευρώνων που το απαρτίζουν. Άλλες κατηγοριοποιήσεις των ΤΝΔ που θα δούμε στη συνέχεια είναι με βάση τον τρόπο με τον οποίο είναι συνδεδεμένοι οι νευρώνες του (αρχιτεκτονική), τον αλγόριθμο που χρησιμοποιείται για την εκπαίδευσή του, και αν η εκπαίδευση γίνεται με εποπτεία ή χωρίς.

Συνοψίζοντας όλα τα παραπάνω, η δομή ενός δικτύου υπολογιστικού νευρώνα αποτυπώνεται στο παρακάτω Σχήμα 3.3 [20].



Σχήμα 3.3 Δομή Δικτύου Υπολογιστικού Νευρώνα

3.3.2 Αρχιτεκτονική ΤΝΔ

Ένα δομικό στοιχείο των ΤΝΔ αποτελεί η αρχιτεκτονική τους. Συνηθίζεται οι νευρώνες να απεικονίζονται ως διατεταγμένοι σε στρώματα. Τυπικά, οι νευρώνες που ανήκουν στο ίδιο στρώμα, συμπεριφέρονται με τον ίδιο τρόπο. **Αυτά που καθορίζουν την συμπεριφορά κάθε νευρώνα είναι η συνάρτηση ενεργοποίησής του και το μοτίβο σταθμισμένων συνδέσεων μέσω των οποίων στέλνει και λαμβάνει σήματα.** Σε κάθε στρώμα λοιπόν οι νευρώνες έχουν συχνά την ίδια συνάρτηση μεταφοράς και το ίδιο μοτίβο σταθμισμένων συνδέσεων με άλλους νευρώνες. Πιο συγκεκριμένα, σε πολλά νευρωνικά δίκτυα, οι νευρώνες μέσα σε ένα στρώμα είτε είναι πλήρως διασυνδεδεμένοι είτε δεν είναι καθόλου διασυνδεδεμένοι. Εάν οποιοσδήποτε νευρώνας σε ένα επίπεδο (για παράδειγμα, το στρώμα των κρυφών μονάδων) συνδέεται με έναν νευρώνα σε ένα άλλο επίπεδο (για παράδειγμα, το επίπεδο εξόδου), τότε κάθε κρυφή μονάδα συνδέεται με κάθε νευρώνα εξόδου.

Ως αρχιτεκτονική δικτύου ορίζεται η διάταξη των νευρώνων σε στρώματα και τα μοτίβα σύνδεσης εντός και μεταξύ των επιπέδων. Πολλά νευρωνικά δίκτυα έχουν ένα στρώμα εισόδου στο οποίο η ενεργοποίηση κάθε μονάδας είναι ίση με ένα εξωτερικό σήμα εισόδου.


Το ΤΝΔ που απεικονίζεται στο Σχήμα 3.2 αποτελείται από μονάδες εισόδου, μονάδες εξόδου και μια κρυφή μονάδα (μια μονάδα που δεν είναι ούτε μονάδα εισόδου ούτε μονάδα εξόδου).

Τα ΤΝΔ ταξινομούνται σε μονοστρωματικά ή πολυστρωματικά. Κατά τον προσδιορισμό του αριθμού των επιπέδων, οι μονάδες εισόδου δεν υπολογίζονται ως επίπεδο, επειδή δεν εκτελούν υπολογισμούς. Ισοδύναμα, ο αριθμός των στρωμάτων στο δίκτυο μπορεί να οριστεί ως ο αριθμός των στρωμάτων σταθμισμένων συνδέσμων διασύνδεσης μεταξύ των πλακών των νευρώνων. Αυτή η άποψη στηρίζεται στο γεγονός ότι τα βάρη σε ένα ΤΝΔ περιέχουν εξαιρετικά σημαντικές πληροφορίες. Το δίκτυο που φαίνεται στο Σχήμα 3.2 έχει δύο στρώματα βαρών.

Τα μονοστρωματικά και πολυστρωματικά ΤΝΔ που απεικονίζονται στα Σχήματα 3.4 και 3.6 είναι παραδείγματα δικτύων τροφοδοσίας, δηλαδή δίκτυα στα οποία τα σήματα ρέουν από τις μονάδες εισόδου προς τις μονάδες εξόδου, με κατεύθυνση προς τα εμπρός. Το πλήρως διασυνδεδεμένο ανταγωνιστικό δίκτυο στο Σχήμα 3.7 είναι ένα παράδειγμα επαναλαμβανόμενου δικτύου, στο οποίο υπάρχουν διαδρομές σήματος κλειστού βρόχου από μια μονάδα πίσω στον εαυτό της.

▪ **Μονοστρωματικό ΤΝΔ**


Ένα δίκτυο μονής στρώσης έχει ένα στρώμα βαρών σύνδεσης. Συχνά, οι μονάδες μπορούν να διακριθούν ως μονάδες εισόδου, οι οποίες λαμβάνουν σήματα από τον έξω κόσμο, και μονάδες εξόδου, από τις οποίες μπορεί να διαβαστεί η απόκριση του δικτύου. Στο τυπικό δίκτυο μονής στρώσης που φαίνεται στο Σχήμα 3.4, οι μονάδες εισόδου είναι πλήρως συνδεδεμένες με μονάδες εξόδου αλλά δεν συνδέονται με άλλες μονάδες εισόδου και οι μονάδες εξόδου δεν συνδέονται με άλλες μονάδες εξόδου. Αντίθετα, η αρχιτεκτονική του δικτύου Hopfield, που φαίνεται στο Σχήμα 3.5, είναι ένα παράδειγμα ενός δικτύου μονού στρώματος στο οποίο όλες οι μονάδες λειτουργούν τόσο ως μονάδες εισόδου όσο και ως μονάδες εξόδου.



Σχήμα 3.4 Μονοστρωματικό ΤΝΔ

Για την ταξινόμηση προτύπων, κάθε μονάδα εξόδου αντιστοιχεί σε μια συγκεκριμένη κατηγορία στην οποία μπορεί να ανήκει ή να μην ανήκει ένα διάνυσμα εισόδου. Σε ένα μονοστρωματικό ΤΝΔ, τα βάρη για μια μονάδα εξόδου δεν επηρεάζουν τα βάρη για άλλες μονάδες εξόδου. Για συσχέτιση προτύπων, μπορεί να χρησιμοποιηθεί η ίδια αρχιτεκτονική, αλλά τώρα το συνολικό μοτίβο των σημάτων εξόδου δίνει το μοτίβο απόκρισης που σχετίζεται με το σήμα εισόδου που προκάλεσε την παραγωγή του.

Αυτά τα δύο παραδείγματα δείχνουν το γεγονός ότι ο ίδιος τύπος δικτυού μπορεί να χρησιμοποιηθεί για διαφορετικά προβλήματα, ανάλογα με την ερμηνεία της απόκρισης του δικτυού. Από την άλλη πλευρά, πιο περίπλοκα προβλήματα χαρτογράφησης μπορεί να απαιτούν ένα δίκτυο πολλαπλών επιπέδων.

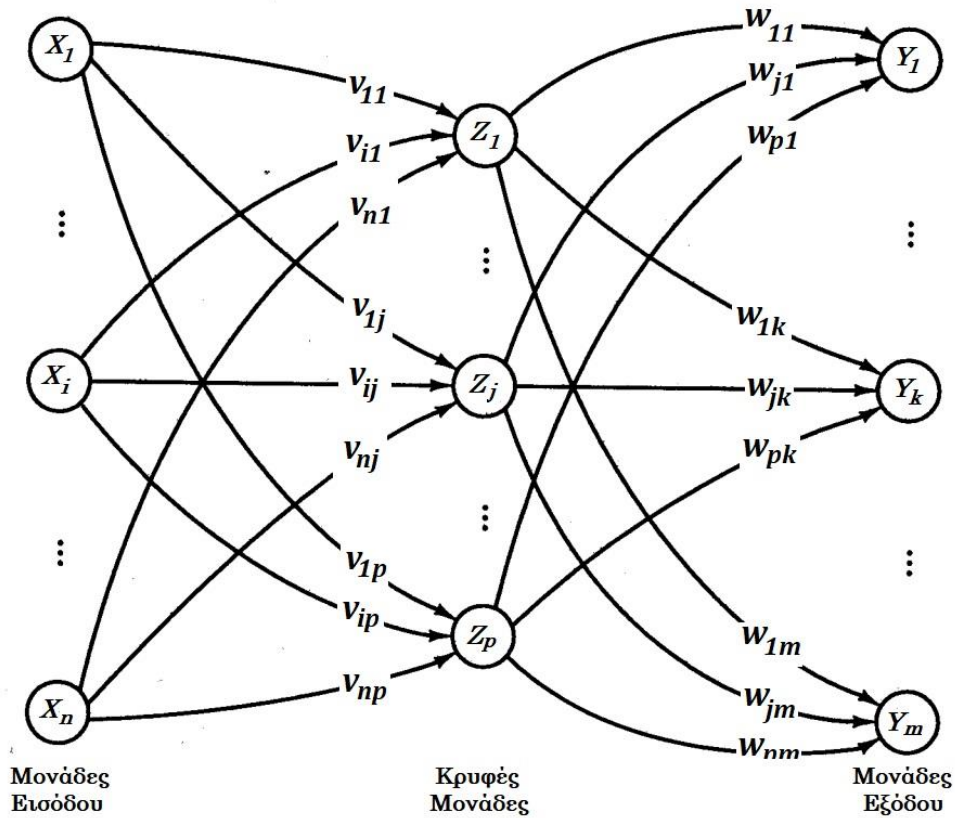


Σχήμα 3.5 Μονοστρωματικό Δίκτυο Τύπου Hopfield

Τα προβλήματα που απαιτούν δίκτυα πολλαπλών στρωμάτων μπορεί να εξακολουθούν να αντιπροσωπεύουν μια ταξινόμηση ή συσχέτιση μοτίβων, το είδος του προβλήματος επηρεάζει την επιλογή της αρχιτεκτονικής, αλλά δεν την καθορίζει μοναδικά.

▪ Πολυστρωματικό ΤΝΔ


Ένα πολυστρωματικό ΤΝΔ είναι ένα δίκτυο με ένα ή περισσότερα στρώματα ή επίπεδα κόμβων, τις λεγόμενες κρυφές μονάδες, μεταξύ των μονάδων εισόδου και των μονάδων εξόδου. Συνήθως, υπάρχει ένα στρώμα βαρών μεταξύ δύο γειτονικών επιπέδων μονάδων (εισόδου, κρυφής ή εξόδου) όπως φαίνεται στο παρακάτω Σχήμα 3.6. Τα πολυστρωματικά δίκτυα μπορούν να λύσουν πιο περίπλοκα προβλήματα από τα μονοστρωματικά, αλλά η εκπαίδευση μπορεί να είναι πιο δύσκολη. Ωστόσο, σε ορισμένες περιπτώσεις, η εκπαίδευση μπορεί να είναι πιο επιτυχημένη, επειδή είναι δυνατό να λυθεί ένα πρόβλημα που ένα μονοστρωματικό δίκτυο δεν μπορεί να εκπαιδευτεί καθόλου για να το εκτελέσει σωστά.



Σχήμα 3.6 Πολυστρωματικό ΤΝΔ

■ Ανταγωνιστικό στρώμα

Ένα ανταγωνιστικό επίπεδο αποτελεί μέρος ενός μεγάλου αριθμού νευρωνικών δικτύων.




Σχήμα 3.7 Ανταγωνιστικό Επίπεδο

Συνήθως, οι ανταγωνιστικές διασυνδέσεις (με βάρη $-\epsilon$) μεταξύ των νευρώνων στο ανταγωνιστικό στρώμα δεν εμφανίζονται στα διαγράμματα

αρχιτεκτονικής για τέτοια δίκτυα. Ένα παράδειγμα της αρχιτεκτονικής για ένα ανταγωνιστικό επίπεδο δίνεται στο Σχήμα 3.7.


Ανάλογα με τον τρόπο διασύνδεσης των επιπέδων και τον τρόπο που επικοινωνούν οι κόμβοι μεταξύ τους, προκύπτουν διάφορες αρχιτεκτονικές ΤΝΔ. Μια κατηγοριοποίηση είναι η εξής:

- **Δίκτυα τύπου Hopfield** όπου οι κόμβοι ενός επιπέδου επιδρούν με τους κόμβους του ιδίου, του αμέσως επόμενου ή και προηγούμενου επιπέδου (Σχήμα 3.5).
- **Δίκτυα πρόσθιας τροφοδότησης (feedforward networks)**, στα οποία η πληροφορία μεταδίδεται από τα χαμηλότερα στα υψηλότερα στρώματα (Σχήμα 3.6).
- **Δίκτυα με ανατροφοδότηση (feedback networks)**, στα οποία υπάρχει τουλάχιστον ένας κλειστός βρόχος (Σχήμα 3.8).



Σχήμα 3.8 ΤΝΔ Ανατροφοδότησης

- **Συμμετρικά αυτόσυσχετιστικά δίκτυα (symmetric auto - associative networks)** όπου τόσο οι συνδέσεις όσο και τα συναπτικά βάρη τους είναι συμμετρικά (Σχήμα 3.9) [16].



Σχήμα 3.9 Συμμετρικό αυτόσυσχετιστικό ΤΝΔ

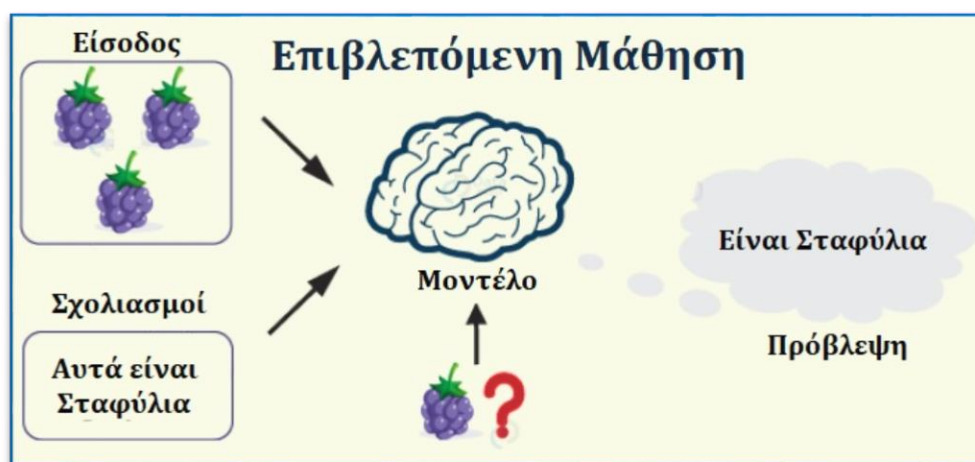
3.3.3 Διαδικασία Μάθησης και Ικανότητα Γενίκευσης των ΤΝΔ

Το βασικότερο χαρακτηριστικό των ΤΝΔ είναι η ικανότητα τους να μαθαίνουν ή να εκπαιδεύονται, για να είναι σε θέση να επιλύουν συγκεκριμένα προβλήματα. Τα ΤΝΔ πραγματοποιούν δύο βασικές λειτουργίες: **τη μάθηση ή εκπαίδευση και την ανάκληση.**

Η **μάθηση ή εκπαίδευση**, αποτελεί η διαδικασία τροποποίησης της τιμής των βαρών του δικτύου, ώστε με δοθέν συγκεκριμένο διάνυσμα εισόδου να παραχθεί συγκεκριμένο διάνυσμα εξόδου. Η **ανάκληση** είναι η διαδικασία υπολογισμού ενός διανύσματος εξόδου για ένα συγκεκριμένο διάνυσμα εισόδου και συγκεκριμένες τιμές βαρών. Είναι, επομένως, πολύ σημαντικό να γίνεται η κατάλληλη εκπαίδευση του δικτύου. Η εκπαίδευση ενός ΤΝΔ επιτυγχάνεται με την βοήθεια κάποιων κανόνων μάθησης καθώς και του αλγόριθμου εκπαίδευσης, με στόχο την βελτιστοποίηση της απόδοσης του δικτύου.

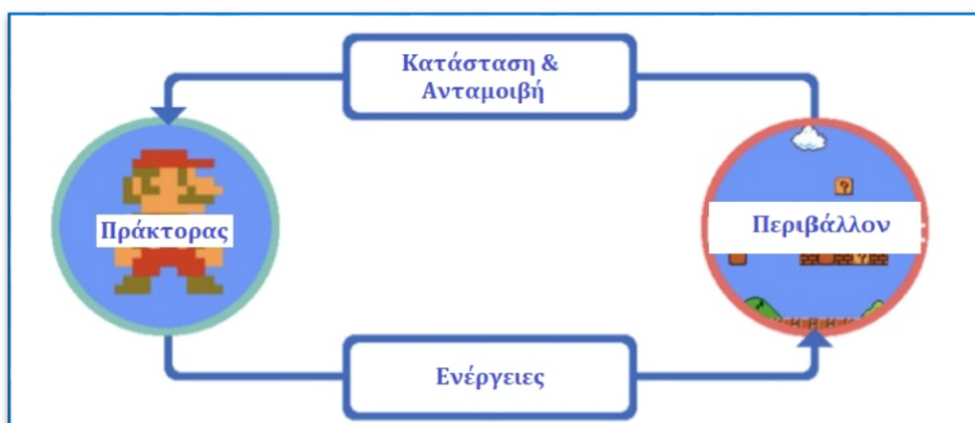
Τρόποι μάθησης ΤΝΔ

1. Η **Επιβλεπόμενη Μάθηση (Supervised Learning)** είναι η διαδικασία μάθησης κατά την οποία έχουμε ως δεδομένα τα διανύσματα εισόδου και την επιθυμητή έξοδο. Αρχικά χρησιμοποιώντας τα αρχικά βάρη, το δίκτυο παράγει έξοδο που αποκλίνει από την επιθυμητή, έχει δηλαδή σφάλμα. Με βάση αυτό το σφάλμα και με την βοήθεια του αλγόριθμου εκπαίδευσης, γίνεται αναπροσαρμογή των αρχικών βαρών. Η επιβλεπόμενη μάθηση είναι η πιο διαδεδομένη διαδικασία μάθησης των ΤΝΔ.



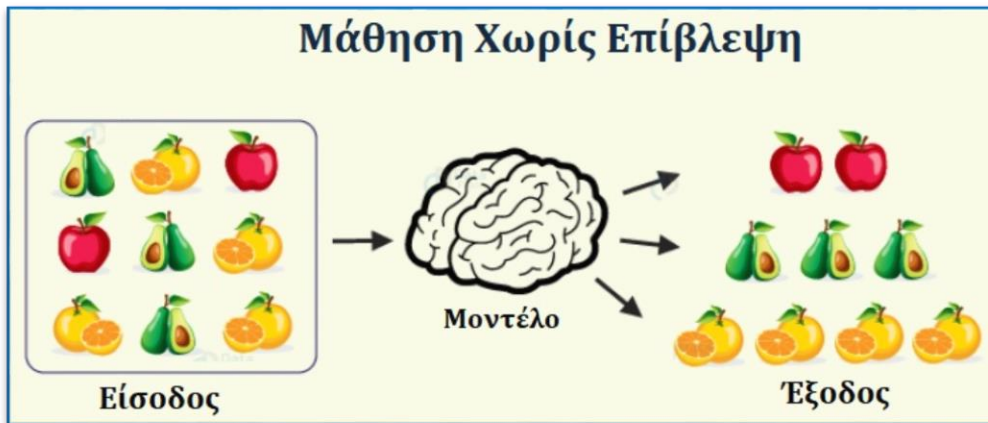
Εικόνα 3.2 Επιβλεπόμενη Μάθηση

2. Η **Ενισχυτική Μάθηση (Reinforcement Learning)** είναι η διαδικασία μάθησης κατά την οποία η έξοδος του δικτύου δεν είναι γνωστή. Αντίθετα χαρακτηρίζεται καλή ή κακή με βάση μια αριθμητική κλίμακα όπου τα βάρη του δικτύου αναπροσαρμόζονται αναλόγως. Επομένως είναι δύσκολο να προσδιορίσουμε πότε θα τερματιστεί η διαδικασία.



Εικόνα 3.3 Ενισχυτική Μάθηση

3. Η **Μάθηση Χωρίς Επίβλεψη (Unsupervised Learning)** είναι η διαδικασία μάθησης κατά την οποία είναι γνωστά μόνο τα διανύσματα εισόδου. Στη συγκεκριμένη περίπτωση το νευρωνικό δίκτυο αυτοοργανώνεται και ομαδοποιεί τα διανύσματα εισόδου χωρίς δεδομένα εκπαίδευσης που να καθορίζουν σε ποια ομάδα ανήκει το κάθε διάνυσμα εισόδου.



Εικόνα 3.4 Μάθηση Χωρίς Επίβλεψη

4. Η **Ημιεπιβλεπόμενη Μάθηση (Semi-supervised learning)** είναι μια μέθοδος μηχανικής μάθησης στην οποία έχουμε δεδομένα εισόδου και ένα κλάσμα δεδομένων εισόδου επισημαίνεται ως έξοδος. Είναι ένας συνδυασμός εποπτευόμενης και χωρίς επίβλεψη μάθησης.



Εικόνα 3.5 Ημιεπιβλεπόμενη Μάθηση

5. Η **Αυτοεποπτική Μάθηση (Self - Supervised Learning)** τα μοντέλα εκπαιδεύονται χωρίς τη χρήση εξωτερικών ετικετών ή επιβλεπτικών σημάτων. Αντί για την προμήθεια ετικετών από ανθρώπινους εκπαιδευτές, τα μοντέλα SSL αξιοποιούν την ύπαρξη δομικών πληροφοριών ή σχέσεων μέσα στα ίδια τα δεδομένα για να ανακαλύψουν ποικίλες αναπαραστάσεις [21].



Εικόνα 3.6 Αυτοεποπτική Μάθηση

6. **Δίκτυα Σταθερών Βαρών (Fixed – Weight Nets).** Άλλοι τύποι νευρωνικών δικτύων μπορούν ακόμη να επιλύσουν προβλήματα περιορισμένης βελτιστοποίησης. Τέτοια δίκτυα λειτουργούν καλά για προβλήματα που μπορούν να προκαλέσουν δυσκολία στις παραδοσιακές τεχνικές, όπως προβλήματα με αντιφατικούς περιορισμούς (δηλαδή, δεν μπορούν να ικανοποιηθούν όλοι οι περιορισμοί ταυτόχρονα). Συχνά, σε τέτοιες περιπτώσεις, μια σχεδόν βέλτιστη λύση (την οποία το δίκτυο μπορεί να βρει) είναι ικανοποιητική. Όταν σχεδιάζονται αυτά τα δίκτυα, τα βάρη ορίζονται για να αντιπροσωπεύουν τους περιορισμούς και την ποσότητα που πρέπει να ελαχιστοποιηθεί ή να μεγιστοποιηθεί.

Αλγόριθμοι Μάθησης με Επίβλεψη

- **Κανόνας Δέλτα (Delta Learning)** όπου η διαφορά μεταξύ πραγματικής και επιθυμητής εξόδου ελαχιστοποιείται μέσω μιας διαδικασίας ελάχιστων τετραγώνων. Ο Κανόνας Δέλτα δεν μπορεί να εφαρμοστεί σε δίκτυα με κρυφά επίπεδα επειδή δεν είναι γνωστή η επιθυμητή έξοδος για τους νευρώνες των κρυφών επιπέδων.
- **Αλγόριθμος Ανάστροφης Μετάδοσης Λάθους (Back Propagation)** κατά τον οποίο η μεταβολή των βαρών βασίζεται στον υπολογισμό της συνεισφοράς κάθε βάρους στο συνολικό σφάλμα.
- **Ανταγωνιστική Μάθηση (Competitive Learning)** κατά την οποία οι τεχνητοί νευρώνες συναγωνίζονται, κατά κάποιο τρόπο, μεταξύ τους και σε δοθείσα είσοδο, μόνο αυτός με τη μεγαλύτερη απόκριση τροποποιεί τα βάρη του.
- **Τυχαία Μάθησης (Random Learning)** κατά την οποία οι μεταβολές στα βάρη εισάγονται τυχαία και ανάλογα με το αν η έξοδος βαλτώνεται ή όχι με


βάση κάποια προκαθορισμένα κριτήρια από τον χρήστη, υιοθετούνται ή απορρίπτονται οι μεταβολές αυτές [22].

Διαδικασία Εκπαίδευσης και Προσαρμογή

Πολλές φορές κατά τη διαδικασία εκπαίδευσης παρουσιάζονται τα εξής προβλήματα:

1. **Υπέρ - Προσαρμογή (Over - Fitting)** είναι το φαινόμενο κατά το οποίο, ενώ το σφάλμα εξόδου είναι μικρό σε σχέση με το επιθυμητό, η απόδοση του δικτύου δεν είναι απαραίτητα καλή. Ο λόγος είναι ότι το δίκτυο προσαρμόζεται πλήρως στα συγκεκριμένα δεδομένα και χάνεται η δυνατότητα γενίκευσης.

2. **Υπό - Προσαρμογή (Under - Trained)** έχουμε όταν η διαδικασία εκπαίδευσης σταματήσει πολύ νωρίς και το αποτέλεσμα δεν είναι ικανοποιητικό. Στο παρακάτω Διάγραμμα 3.1 παρουσιάζονται και οι δυο περιπτώσεις καθώς και η περίπτωση της **Καλής Προσαρμογής (Well - Trained)**.




Διάγραμμα 3.1 Διαδικασία Εκπαίδευσης και Προσαρμογή

Συναρτήσεις Μεταφοράς

Η βασική λειτουργία ενός τεχνητού νευρώνα περιλαμβάνει την άθροιση του σταθμισμένου σήματος εισόδου του και την εφαρμογή μιας συνάρτησης εξόδου ή ενεργοποίησης. Για τις μονάδες εισόδου, αυτή η συνάρτηση είναι η γραμμική συνάρτηση (Διάγραμμα 3.2). Τυπικά, η ίδια συνάρτηση ενεργοποίησης χρησιμοποιείται για όλους τους νευρώνες σε οποιοδήποτε συγκεκριμένο στρώμα ενός νευρωνικού δικτύου, αν και αυτό δεν απαιτείται. Στις περισσότερες περιπτώσεις, χρησιμοποιείται μια μη γραμμική συνάρτηση ενεργοποίησης. Προκειμένου να επιτευχθούν τα πλεονεκτήματα των πολυστρωματικών δικτύων, σε σύγκριση με τις περιορισμένες δυνατότητες των μονοστρωματικών, απαιτούνται μη γραμμικές συναρτήσεις, καθώς τα αποτελέσματα της τροφοδοσίας ενός σήματος μέσω δύο ή περισσότερων στρωμάτων γραμμικών στοιχείων επεξεργασίας, δηλαδή στοιχείων με συναρτήσεις γραμμικής ενεργοποίησης — δεν διαφέρουν από αυτό που μπορεί να ληφθεί χρησιμοποιώντας ένα μόνο στρώμα.

1. Γραμμική Συνάρτηση


$$f(x) = x \text{ για κάθε } x$$



Διάγραμμα 3.2 Γραμμική Συνάρτηση Μεταφοράς

2. Βηματική Συνάρτηση (με όριο θ)

$$f(x) = \begin{cases} 1 & \text{αν } x \geq \theta \\ 0 & \text{αν } x < \theta \end{cases}$$



Διάγραμμα 3.3 Δυαδική Βηματική Συνάρτηση


Τα μονοστρωματικά δίκτυα χρησιμοποιούν συχνά μια συνάρτηση βήματος για να μετατρέψουν την καθαρή είσοδο, η οποία είναι μια μεταβλητή με συνεχή τιμή, σε μια μονάδα εξόδου που είναι ένα δυαδικό (1 ή 0) ή διπολικό (1 ή -1) σήμα. Η συνάρτηση δυαδικού βήματος (Διάγραμμα 3.3) είναι επίσης γνωστή ως συνάρτηση κατωφλίου ή συνάρτηση Heaviside.

3. Δυαδική Σιγμοειδής

Οι σιγμοειδείς συναρτήσεις (καμπύλες σε σχήμα S) είναι χρήσιμες συναρτήσεις ενεργοποίησης. Η λογιστική συνάρτηση και οι υπερβολικές συναρτήσεις εφραπτομένης είναι οι πιο κοινές. Είναι ιδιαίτερα πλεονεκτήματα

για χρήση σε νευρωνικά δίκτυα που εκπαιδεύονται με οπισθοδρόμηση (back propagation), επειδή η απλή σχέση μεταξύ της τιμής της συνάρτησης σε ένα σημείο και της τιμής της παραγώγου σε αυτό το σημείο μειώνει την υπολογιστική επιβάρυνση κατά τη διάρκεια της εκπαίδευσης.


Η λογαριθμική σιγμοειδής συνάρτηση, είναι μια σιγμοειδής συνάρτηση με εύρος από 0 έως 1, χρησιμοποιείται συχνά ως συνάρτηση ενεργοποίησης για νευρωνικά δίκτυα στα οποία οι επιθυμητές τιμές εξόδου είτε είναι δυαδικές είτε βρίσκονται στο διάστημα μεταξύ 0 και 1. Για να τονιστεί το εύρος της συνάρτησης, θα ονομαστεί δυαδική σιγμοειδής. Ονομάζεται επίσης λογαριθμική σιγμοειδής. Αυτή η συνάρτηση απεικονίζεται στο Διάγραμμα 3.4 για δύο τιμές της παραμέτρου κλίσης σ .



Διάγραμμα 3.4 Δυαδική Σιγμοειδής με Παραμέτρους Κλίσης $\sigma=1$ και $\sigma=3$

4. Διπολική Σιγμοειδής

Η λογαριθμική σιγμοειδής συνάρτηση μπορεί να κλιμακωθεί ώστε να έχει οποιοδήποτε εύρος τιμών που είναι κατάλληλο για ένα δεδομένο πρόβλημα. Το πιο κοινό εύρος είναι από -1 έως 1. Σε αυτή την περίπτωση ονομάζεται διπολική σιγμοειδής και απεικονίζεται στο Διάγραμμα 3.5.



Διάγραμμα 3.5 Διπολική Σιγμοειδής

$$g(x) = 2f(x) - 1 = \frac{2}{1 + e^{(-\sigma x)}} - 1 = \frac{1 - e^{(-\sigma x)}}{1 + e^{(-\sigma x)}}$$

$$g'(x) = \frac{\sigma}{2} [1 + g(x)][1 - g(x)]$$

Η διπολική σιγμοειδής σχετίζεται στενά με την υπερβολική συνάρτηση εφαπτομένης, η οποία χρησιμοποιείται επίσης συχνά ως συνάρτηση ενεργοποίησης όταν το επιθυμητό εύρος τιμών εξόδου είναι μεταξύ -1 και 1. Η αντιστοιχία μεταξύ των δύο συναρτήσεων για $\sigma = 1$ προκύπτει:

$$g(x) = \frac{1 - e^{(-x)}}{1 + e^{(-x)}}$$

και η υπερβολική εφαπτομένη είναι

$$h(x) = \frac{e^{(x)} - e^{(-x)}}{e^{(x)} + e^{(-x)}} = \frac{1 - e^{(-2x)}}{1 + e^{(-2x)}}$$

η παράγωγος της υπερβολικής εφαπτομένης είναι

$$h'(x) = [1 + h(x)][1 - h(x)].$$

Για δυαδικά δεδομένα (αντί για δεδομένα συνεχούς αξίας στην περιοχή από 0 έως 1), είναι συνήθως προτιμότερο να μετατραπεί σε διπολική μορφή και να χρησιμοποιηθεί η διπολική σιγμοειδής συνάρτηση ή υπερβολική συνάρτηση εφαπτομένης [19].

3.3.4 Κύρια Χαρακτηριστικά ΤΝΔ

Τα ΤΝΔ προσπαθούν να συνδυάσουν τον ανθρώπινο με τον αφηρημένο μαθηματικό τρόπο σκέψης διαθέτοντας πληθώρα **πλεονεκτημάτων** όπως:

1. **Κατανομή των Πληροφοριών.** Ο παραδοσιακός προγραμματισμός αποθηκεύει τις πληροφορίες σε βάσεις δεδομένων, σε αντίθεση με τα ΤΝΔ

όπου οι πληροφορίες διανέμονται σε όλο το δίκτυο με αποτέλεσμα, η μερική απώλεια πληροφοριών να μην αναστέλλει τη λειτουργία του συνολικού δικτύου.

2. **Δυνατότητα Εργασίας με Μερική Γνώση.** Μετά την εκπαίδευση των ΤΝΔ, τα δεδομένα μπορούν να παράγουν εξόδους ακόμα και με ελλιπή πληροφορία χωρίς να εξαρτάται η απώλεια απόδοσης από αυτή την απουσία πληροφοριών.
3. **Ανοχή σε Σφάλματα.** Ακόμη και αν εμφανιστούν προβλήματα σε ένα ή περισσότερους νευρώνες ενός ΤΝΔ, τα δίκτυα συνεχίζουν να λειτουργούν παράγοντας εξόδους. Αυτή η ενσωματωμένη ανοχή στα σφάλματα βελτιώνει την αξιοπιστία.
4. **Κατανεμημένη Μνήμη.** Η εκμάθηση εξαρτάται από την ποιότητα των παραδειγμάτων και τη διδασκαλία του δικτύου με στόχο την επιθυμητή έξοδο. Συνεπώς, η επιτυχία του δικτύου έγκειται στην ποιότητα των παραδειγμάτων.
5. **Σταδιακή Επιδείνωση.** Η απόδοση ενός δικτύου ενδέχεται να επιβραδυνθεί με τον χρόνο και υφίσταται σχετική υποβάθμιση. Το πρόβλημα του δικτύου όμως, δεν διαβρώνει αμέσως την λειτουργία του.
6. **Ικανότητα Μηχανικής Μάθησης.** Τα ΤΝΔ δίκτυα μαθαίνουν γεγονότα και λαμβάνουν αποφάσεις βασιζόμενα σε παρόμοια γεγονότα.
7. **Δυνατότητα Παράλληλης Επεξεργασίας.** Τα ΤΝΔ μπορούν να εκτελούν πολλαπλές εργασίες ταυτόχρονα, λόγω της δυνατότητάς τους για παράλληλη επεξεργασία.

Η ευελιξία των ΤΝΔ αποτελεί ισχυρό εργαλείο, αλλά ταυτόχρονα μπορεί να αποτελεί και περιορισμό. Καθώς το δίκτυο μεγαλώνει, γίνεται πιο πολύπλοκο και εύθραυστο. Η μεγάλη πολυπλοκότητα μπορεί να καθιστά δυσκολότερη τη διαχείριση και την εκπαίδευσή του, και μπορεί να οδηγεί σε δυσκολίες στην αντιμετώπιση προβλημάτων. Τα κύρια **μειονεκτήματα** που εμφανίζουν τα ΤΝΔ είναι τα εξής:

1. **Εξάρτηση από το υλικό.** Τα ΤΝΔ απαιτούν επεξεργαστές με παράλληλη επεξεργασία, ανάλογη με τη δομή τους. Συνεπώς, η υλοποίησή τους εξαρτάται από τον τύπο της διαθέσιμης εξοπλιστικής υποδομής.
2. **Ανεξήγητη συμπεριφορά.** Αποτελεί το κυριότερο πρόβλημα των ΤΝΔ. Όταν ένα ΤΝΔ παράγει μια λύση, δεν παρέχει εξηγήσεις για το γιατί και το πώς. Αυτό μειώνει την εμπιστοσύνη στο δίκτυο.

3. **Καθορισμός κατάλληλης δομής.** Δεν υπάρχει συγκεκριμένος κανόνας για τον τρόπο καθορισμού της δομής των ΤΝΔ. Η βέλτιστη δομή επιτυγχάνεται μέσω εμπειρίας και δοκιμής.
4. **Δυσκολία προβολής του προβλήματος.** Τα ΤΝΔ μπορούν να λειτουργήσουν με αριθμητικές πληροφορίες, συνεπώς τα προβλήματα πρέπει να μεταφραστούν σε αριθμητικές τιμές πριν παρουσιαστούν στο ΤΝΔ. Ο τρόπος παρουσίασης επηρεάζει απευθείας την απόδοση του δικτύου και αυτό εξαρτάται από την ικανότητα του χρήστη.
5. **Άγνωστη διάρκεια εκπαίδευσης.** Το δίκτυο σταματά την εκπαίδευση όταν επιτευχθεί ένα συγκεκριμένο επίπεδο σφάλματος στα δείγματα, που σημαίνει ότι η εκπαίδευση έχει ολοκληρωθεί χωρίς να εγγυάται βέλτιστα αποτελέσματα.

Ως συνεχώς και ταχέως αναπτυσσόμενα, τα ΤΝΔ με την πάροδο του χρόνου εισέρχονται σε ολοένα και περισσότερες εφαρμογές, αυξάνοντας έτσι τα πλεονεκτήματά τους και απορροφώντας σταδιακά τα μειονεκτήματά τους [23].

3.3.5 Εφαρμογές ΤΝΔ

Για να αντιληφθούμε το μεγάλο εύρος της χρησιμότητας των ΤΝΔ παραθέτουμε παρακάτω κάποιους τομείς στους οποίους εφαρμόζονται.

- **Μηχανική Μάθηση/Αναγνώριση Προτύπων** (φωνητική αναγνώριση, αναγνώριση γραφικού χαρακτήρα, εικόνας, προσώπων)
- **Κατηγοριοποίηση/Ταξινόμηση Δεδομένων** (εισερχόμενων μηνυμάτων σχετικού περιεχομένου, ανεπιθύμητων)
- **Πρόβλεψη/Χρονοπρογραμματισμός/Ανάλυση Δεδομένων** (εξωτερικής θερμοκρασίας, τιμών ακινήτων ή μετοχών, ασθένειας μέσω καταγραφής συμπτωμάτων, ανάλυση δεδομένων από επιστημονικές έρευνες)
- **Προσομοίωση** (φυσικών φαινομένων)
- **Σχεδιασμός Ενεργειών/Τεχνολογική Ασφάλεια** (αυτόνομα οχήματα, ανίχνευση εμποδίων, πρόβλεψης ατυχημάτων)
- **Επιστήμη της Οικονομίας** (διαχείριση ρίσκου, εντοπισμός απάτης)

Τα ΤΝΔ ως Εργαλεία Πρόβλεψης

Όπως διαπιστώνουμε από τα παραπάνω, τα ΤΝΔ συγκριτικά με άλλες μεθόδους πρόβλεψης, εμφανίζουν πλεονεκτήματα όπως και μειονεκτήματα. Η εκπαίδευση του δικτύου βασίζεται σε ιστορικά δεδομένα και αυτό γίνεται με τη

χρήση χρονοσειρών ως δεδομένα εισόδου και παρέχοντας ως αποτέλεσμα την επιθυμητή πρόβλεψη χρονοσειράς. Συνοπτικά αυτό που προσπαθεί είναι ο εντοπισμός της σπουδαιότητας ορισμένων ιστορικών τιμών με στόχο την προσέγγιση μελλοντικών τιμών, μέσω της υποστήριξης μη γραμμικών συναρτήσεων.


Επίσης, ενώ η πρόβλεψη αποτελούσε ανέκαθεν περιοχή εφαρμογής της γραμμικής στατιστικής, τα ΤΝΔ είναι μη γραμμικά. Οι παραδοσιακές προσεγγίσεις στην πρόγνωση χρονοσειρών (time series), όπως οι μέθοδοι Box-Jenkins και ARMA, προϋποθέτουν ότι οι υπό μελέτη χρονοσειρές προέρχονται από γραμμικές διαδικασίες. Τα γραμμικά μοντέλα έχουν το πλεονέκτημα της κατανόησης και ανάλυσής τους με κάθε λεπτομέρεια καθώς και τη δυνατότητα εύκολης εξήγησης και υλοποίησης. Ωστόσο, μπορεί να αποδειχθούν εντελώς ακατάλληλα εάν ο υποκείμενος μηχανισμός είναι μη γραμμικός. Είναι παράλογη η εκ των προτέρων υπόθεση ότι οι συγκεκριμένες χρονοσειρές παράγονται από γραμμικές διαδικασίες.

Στην πραγματικότητα, τα σύγχρονα συστήματα και ιδιαίτερα τα μακροοικονομικά είναι κατά πλειοψηφία μη γραμμικά. Ωστόσο αυτά τα μη γραμμικά μοντέλα αντιμετωπίζουν κάποιους περιορισμούς υπό την έννοια ότι είναι αναγκαίο να υποτεθεί μια ρητή σχέση για τα υπό μελέτη δεδομένα, όταν ελάχιστη γνώση του υποκείμενου νόμου είναι διαθέσιμη. Στην πραγματικότητα, η διαμόρφωση ενός μη γραμμικού μοντέλου για ένα συγκεκριμένο σύνολο δεδομένων αποτελεί ένα πολύ δύσκολο εγχείρημα, εφόσον υπάρχουν πολλά πιθανά μη γραμμικά πρότυπα και ένα προκαθορισμένο μη γραμμικό μοντέλο μπορεί να αποδειχθεί μη αρκετά γενικό για την σύλληψη όλων των σημαντικών χαρακτηριστικών. Τα ΤΝΔ, που αποτελούν μη γραμμικές, οδηγούμενες από τα δεδομένα, προσεγγίσεις σε αντίθεση με τα παραπάνω μη γραμμικά μοντέλα, είναι ικανά για την εκτέλεση μη γραμμικής μοντελοποίησης χωρίς να απαιτούν *a priori* γνώση σχετικά με τη σχέση των μεταβλητών εισόδου και εξόδου. **Συνεπώς, τα ΤΝΔ συνιστούν ένα πιο γενικό και ευέλικτο εργαλείο μοντελοποίησης για την διεξαγωγή προβλέψεων [24].**

3.4 Νευρο – Ασαφή Συστήματα

3.4.1 Ασαφείς Νευρώνες

Δομική μονάδα των νευρο – ασαφών συστημάτων αποτελούν οι ασαφείς νευρώνες (Σχήμα 3.10).



Σχήμα 3.10 Ασαφείς Νευρώνες

όπου:

x_1, x_2, \dots, x_m οι είσοδοι του νευρώνα

w_1, w_2, \dots, w_m τα βάρη των συνάψεων

f η συνάρτηση συμμετοχής του νευρώνα

a η συνάρτηση ενεργοποίηση του νευρώνα και

y η έξοδος του νευρώνα

Οι ασαφείς νευρώνες χωρίζονται στις παρακάτω κατηγορίες:

■ Νευρώνες Συμμετοχής

Όπως αναφέρθηκε σε προηγούμενη υποενότητα, οι συνηθέστερες μορφές συναρτήσεων συμμετοχής είναι η τριγωνική, η γκαουσιανή, η τραπεζοειδής, η κανονική και λοιπά. Οι παραπάνω συναρτήσεις συμμετοχής μπορούν να υλοποιηθούν με τη χρήση ενός νευρώνα. Αυτό μπορεί να γίνει, θεωρώντας ότι ο νευρώνας δέχεται ως είσοδο το x και δίνει έξοδο $A(x)$, απαιτώντας η συνάρτηση συμμετοχής του να έχει τη μορφή A . Αν δηλαδή υποθέσουμε ότι η συνάρτηση συμμετοχής είναι η κανονική, τότε για να υλοποιηθεί, πρέπει η συνάρτηση ενεργοποίησης να είναι:

$$a(u) = \exp\left(-\frac{(u - m)^2}{\sigma^2}\right)$$

όπου m κέντρο της συνάρτησης συμμετοχής και σ το εύρος της.

■ Λειτουργικοί Νευρώνες

Με τον ίδιο τρόπο μπορούν να υλοποιηθούν οι βασικές πράξεις των ασαφών συνόλων. Οι πράξεις αυτές στηρίζονται σε λειτουργίες όπως η τ-νόρμα, η σ-νόρμα, το ασαφές συμπλήρωμα κλπ. Οι παραπάνω λειτουργίες μπορούν να

αντικαταστήσουν τη συνάρτηση ενεργοποίησης του νευρώνα, αν θεωρήσουμε ότι οι είσοδοι δεν αθροίζονται πολλαπλασιασμένοι με βάρη όπως στους κλασσικούς νευρώνες. Για να μπορούμε όμως να εφαρμόσουμε τους αλγορίθμους μάθησης (π.χ. τον αλγόριθμο αντίστροφης διάδοσης back propagation), θα πρέπει οι λειτουργίες να είναι παραγωγίσιμες.

Για την υλοποίηση των ασαφών λειτουργιών μπορούμε να επεκτείνουμε την έννοια της συνάρτησης μεταφοράς του νευρώνα. Στην περίπτωση αυτή ο νευρώνας δεν υλοποιεί το αναλυτικό γινόμενο της εισόδου με το διάνυσμα των βαρών αλλά την πράξη της συγκεκριμένης ασαφούς λειτουργίας θεωρώντας ότι όλα τα βάρη είναι 1, ως συνάρτηση συμμετοχής λαμβάνεται η:

$$a(u) = \begin{cases} 1, u > 1 \\ u, 0 \leq u \leq 1 \\ 0, u < 0 \end{cases}$$

▪ Συνθετικοί Νευρώνες

Προηγουμένως παρουσιάστηκε η σύνθεση ασαφών σχέσεων. Η πράξη της σύνθεσης αποτελεί μια γενίκευση της πράξης του αναλυτικού γινομένου των διανυσμάτων και υλοποιείται από τη συνάρτηση μεταφοράς f των νευρώνων. Η μορφή του νευρώνα είναι η ίδια και ορίζεται από τις εξισώσεις:

$$f = \text{union } t(x_i, w_i), i \in N_m$$

$$y = a(u)$$

όπου union είναι μια σ-νόρμα και t είναι μια τ-νόρμα. Ως συνάρτηση ενεργοποίησης θεωρείται η συνάρτηση αναρρίχησης. Παρατηρούμε ότι ο συνθετικός νευρώνας είναι μια γενίκευση του κλασσικού νευρώνα, αφού η πράξη της φραγμένης άθροισης, η οποία εξασφαλίζεται από τη συνάρτηση ενεργοποίησης, είναι μια ειδική περίπτωση της φραγμένης ένωσης, ενώ το γινόμενο είναι μια ειδική περίπτωση της ασαφούς τομής.

3.4.2 Προσαρμοστικά Δίκτυα (Adaptive Networks)

Προσαρμοστικό δίκτυο ονομάζεται το δίκτυο που αποτελείται από έναν αριθμό κόμβων, συνδεδεμένων μέσω κατευθυντικών συνδέσμων. Κάθε κόμβος αναπαριστά μια μονάδα επεξεργασίας. Οι σύνδεσμοι των κόμβων προσδιορίζουν την αιτιολογική σχέση (causal relationship) μεταξύ των συνδεδεμένων κόμβων. Προσαρμοστικός είναι ο κόμβος, όλος ή μέρος του, που οι έξοδοί του εξαρτώνται από προσαρμοζόμενες παραμέτρους που ανήκουν σε αυτόν. Οι κανόνες

εκπαίδευσης προσδιορίζουν τον τρόπο με τον οποίο αυτές οι παράμετροι θα πρέπει να αλλάζουν ώστε να ελαχιστοποιείται το προκαθορισμένο μέτρο σφάλματος (error measure).

Τα προσαρμοστικά δίκτυα χρησιμοποιούνται για ταυτοποίηση συστήματος. Σε κάθε περίπτωση στόχος μας είναι να βρούμε μια κατάλληλη αρχιτεκτονική για το δίκτυο και να θέσουμε ένα σύνολο παραμέτρων που μπορούν να μοντελοποιήσουν καλύτερα ένα σύστημα – στόχο. Το σύστημα αυτό περιγράφεται από ένα σύνολο ζευγών δεδομένων εισόδου – εξόδου.

Ο βασικός κανόνας για την εύρεση ενός προσαρμοστικού δικτύου είναι η απότομη φθίνουσα μέθοδος, στην οποία το βαθμωτό διάνυσμα προκύπτει από επιτυχείς επικλήσεις του κανόνα της αλυσίδας. Αυτή η μέθοδος χρησιμοποιείται και για την εύρεση του βαθμωτού διανύσματος σε ένα νευρωνικό δίκτυο πολλών επιπέδων. Όπως αναφέρθηκε και σε προηγούμενη υποενότητα, η μέθοδος ονομάζεται κανόνας οπισθοδρόμησης διάδοσης (back propagation learning rule).


Για να μετατραπεί ένα ασαφές σύστημα, προσαρμοστικό, θα πρέπει να γνωρίζουμε τις παραγώγους της συνάρτησης συμμετοχής ως προς το όρισμα εισόδου και τις παραμέτρους. Αυτές οι πληροφορίες από τις παραγώγους παίζουν σημαντικό ρόλο στη μάθηση και την προσαρμογή ενός ασαφούς συστήματος.

3.4.3 Αρχιτεκτονική Προσαρμοστικών Δικτύων

Όπως φανερώνει και η ονομασία, ένα προσαρμοστικό δίκτυο παρουσιάζει τέτοια δομή, ώστε η συνολική συμπεριφορά εισόδου-εξόδου να διαμορφώνεται από ένα σύνολο τροποποιήσιμων παραμέτρων. Πιο συγκεκριμένα, ένα προσαρμοστικό δίκτυο αποτελείται από ένα σύνολο κόμβων συνδεδεμένων με προσανατολισμένους συνδέσμους. Κάθε κόμβος εκτελεί μια συγκεκριμένη λειτουργία στα εισερχόμενα σήματα, για να παράξει μια μονήρη έξοδο. Επιπλέον κάθε σύνδεσμος καθορίζει την κατεύθυνση ροής του σήματος μεταξύ των κόμβων. Συνήθως η συνάρτηση κόμβου είναι μια παραμετρική συνάρτηση με τροποποιήσιμες παραμέτρους. Αλλάζοντας τις παραμέτρους, μπορούμε να αλλάξουμε την λειτουργία κόμβου καθώς και τη συνολική συμπεριφορά του δικτύου.


Οι σύνδεσμοι σε ένα προσαρμοστικό δίκτυο χρησιμοποιούνται μόνο για να προσδιορίσουν την κατεύθυνση του σήματος εξόδου. Γενικά δεν υπάρχουν βάρη

ή παράμετροι σχετιζόμενοι με συνδέσμους. Στο Σχήμα 3.11 παρουσιάζεται ένα προσαρμοστικό δίκτυο με δύο εισόδους και δύο εξόδους.



Σχήμα 3.11 Feed - Forward Προσαρμοστικό Δίκτυο με Επίπεδα

Οι παράμετροι ενός προσαρμοστικού δικτύου είναι καταναμεημένοι στους κόμβους, έτσι κάθε κόμβος περιέχει ένα τοπικό σύνολο των παραμέτρων. Η ένωση αυτών των τοπικών συνόλων είναι το ολικό σύνολο παραμέτρων του δικτύου. Αν το σύνολο παραμέτρων ενός κόμβου δεν είναι κενό, τότε η λειτουργία του κόμβου εξαρτάται από τις τιμές των παραμέτρων. Στα σχήματα, αναπαριστούμε τον προσαρμοστικό κόμβο αυτού του είδους με ένα τετράγωνο. Αντιθέτως, αν ο κόμβος περιέχει κενό σύνολο παραμέτρων, τότε η λειτουργία του είναι καθορισμένη. Αναπαριστούμε τον προκαθορισμένο κόμβο με ένα κύκλο (Σχήμα 3.12). Κάθε προσαρμοστικός κόμβος μπορεί να διασπαστεί σε ένα προκαθορισμένο κόμβο και ένα ή περισσότερους κόμβους παραμέτρων.




Σχήμα 3.12 (α) Ένας Μονός Κόμβος (β) Ένα Πρόβλημα έχει Κοινές Παραμέτρους

3.4.4 Καταμερισμός Παραμέτρων στο Δίκτυο


Στο Σχήμα 3.12(α) παρουσιάζεται ένα προσαρμοστικό δίκτυο με έναν μόνο κόμβο, το οποίο μπορεί να αναπαρασταθεί σαν $y = f(x, a)$ όπου x , y

είναι η είσοδος και έξοδος αντίστοιχα και a η παράμετρος του κόμβου. Μια ισοδύναμη απεικόνιση είναι να μεταφέρουμε την παράμετρο έξω από τον κόμβο και να την τοποθετήσουμε σε έναν κόμβο παράμετρο. Αυτός ο κόμβος είναι μια ειδική περίπτωση ενός προσαρμοστικού κόμβου στον οποίο δεν υπάρχουν είσοδοι και η έξοδος είναι η ίδια η παράμετρος. Ο κόμβος παράμετρος είναι χρήσιμος στην επίλυση συγκεκριμένων αντιπροσωπευτικών προβλημάτων. Στο παράδειγμα καταμερισμού παραμέτρων στο Σχήμα 3.12(b) οι δυο προσαρμοστικοί κόμβοι $u = g(x, a)$ και $u = h(y, a)$ μοιράζονται την ίδια παράμετρο a . Βγάζοντας την παράμετρο και τοποθετώντας την μέσα σε έναν κόμβο παράμετρο, μπορούμε να ενσωματώσουμε τις απαιτήσεις του καταμερισμού παραμέτρων μέσα στην αρχιτεκτονική σχεδίαση του δικτύου. Αυτό απλοποιεί την αναπαράσταση του δικτύου καθώς επίσης και την εφαρμογή του σε λογισμικό.

Τα προσαρμοστικά δίκτυα τοποθετούνται σε δύο κύριες κατηγορίες με βάση τον τύπο των διασυνδέσεων που εμφανίζουν: **εμπροσθόδρομα** δίκτυα (feedward) και **επαναληπτικά**. Το προσαρμοστικό δίκτυο που παρουσιάζεται στο Σχήμα 3.13 είναι εμπροσθόδρομο.



Σχήμα 3.13 Εμπροσθόδρομο Προσαρμοστικό Δίκτυο



Σχήμα 3.14 Επαναληπτικό Προσαρμοστικό Δίκτυο

Η έξοδος κάθε κόμβου διαδίδεται από την πλευρά της εισόδου (αριστερά) προς την πλευρά της εξόδου (δεξιά). Αν υπάρχει σύνδεσμος ανάδρασης που σχηματίζει κυκλικό μονοπάτι στο δίκτυο, τότε το δίκτυο

είναι επαναληπτικό (Σχήμα 3.14). Στα γραφήματα, ένα εμπροσθόδρομο δίκτυο αναπαριστάται από ένα κυκλικό κατευθυνόμενο γράφημα που δεν περιέχει κατευθυνόμενους κύκλους, ενώ ένα επαναληπτικό δίκτυο περιέχει τουλάχιστον ένα κατευθυνόμενο κύκλο.

Στην αναπαράσταση με επίπεδα του εμπροσθόδρομου προσαρμοστικού δικτύου στο Σχήμα 3.12, δεν υπάρχουν σύνδεσμοι μεταξύ κόμβων στο ίδιο επίπεδο, και οι έξοδοι των κόμβων σε ένα συγκεκριμένο επίπεδο είναι πάντα συνδεδεμένες με κόμβους σε διαδοχικά επίπεδα. Αυτή η αναπαράσταση είναι συνήθως προτιμητέα λόγω της εύκολης διαμόρφωσής της, αφού οι κόμβοι ίδιου επιπέδου έχουν την ίδια λειτουργία ή γεννούν το ίδιο επίπεδο αφαίρεσης όσων αφορά τα διανύσματα εισόδου.


Μια άλλη αναπαράσταση εμπροσθόδρομου δικτύου είναι η αναπαράσταση τοπολογικής ταξινόμησης η οποία παρουσιάζει τους κόμβους σε μια διατεταγμένη ακολουθία 1,2,3,..., τέτοια που να μην υπάρχουν σύνδεσμοι από τον κόμβο i στον κόμβο j , οποτεδήποτε $i \geq j$ (Σχήμα 3.13). Αυτή η αναπαράσταση είναι λιγότερο διαμορφώσιμη από ότι η αναπαράσταση με επίπεδα, όμως διευκολύνει τον σχηματισμό κανόνων εκπαίδευσης. Η αναπαράσταση τοπολογικής ταξινόμησης είναι στην πραγματικότητα μια ειδική περίπτωση της αναπαράστασης με επίπεδα, με έναν κόμβο ανά επίπεδο.

Ένα εμπροσθόδρομο προσαρμοστικό δίκτυο είναι στην πραγματικότητα μια στατική αντιστοίχιση μεταξύ των χωρών εισόδου και εξόδου. Αυτή η αντιστοιχία μπορεί να είναι μια απλή γραμμική ή μη γραμμική σχέση, εξαρτώμενη από την δομή του δικτύου (διάταξη κόμβων και συνδέσεων) και τη λειτουργία κάθε κόμβου. Για να κατασκευάσουμε ένα προσαρμοστικό δίκτυο χρησιμοποιούμε ένα σύνολο δεδομένων για εκπαίδευση και κάποιες διαδικασίες όπως οι κανόνες εκπαίδευσης ή οι προσαρμοστικοί αλγόριθμοι για την τροποποίηση των παραμέτρων με σκοπό τη βελτίωση της απόδοσης του δικτύου. Συνήθως η απόδοση ενός δικτύου μετριέται ως η διαφορά μεταξύ επιθυμητής και πραγματικής εξόδου, κάτω από τις ίδιες συνθήκες.

3.4.5 Παραδείγματα Προσαρμοστικών Δικτύων

- Προσαρμοστικό Δίκτυο με έναν Γραμμικό Κόμβο

Στο παρακάτω Σχήμα 3.15 απεικονίζεται ένα προσαρμοστικό δίκτυο με ένα κόμβο.




Σχήμα 3.15 Γραμμικό Προσαρμοστικό Δίκτυο με Ένα κόμβο

Σε αυτό ορίζεται $x_3 = f_3(x_1, x_2; a_1 a_2 a_3) = a_1 x_1 + a_2 x_2 + a_3$, όπου x_1, x_2 είναι οι είσοδοι και a_1, a_2, a_3 είναι οι τροποποιήσιμες παράμετροι. Η συνάρτηση προσδιορίζει ένα επίπεδο σε έναν χώρο x_1 - x_2 . Βάζοντας διάφορες τιμές για τις παραμέτρους, μπορούμε να τοποθετήσουμε αυτό το επίπεδο αυθαίρετα όπως εμείς θέλουμε. Χρησιμοποιώντας το τετραφωνικό σφάλμα ως το σφάλμα μέτρησης για το δίκτυο, μπορούμε να αναγνωρίσουμε τις βέλτιστες παραμέτρους μέσω της μεθόδου εκτίμηση των γραμμικών ελαχίστων τετραγώνων.

▪ Δίκτυο Perceptron

Εάν στο παραπάνω δίκτυο προσθέσουμε ένα επιπλέον κόμβο, ώστε να επιτρέψουμε στην έξοδο του δικτύου να παίρνει μόνο δυο τιμές 0 και 1, τότε παίρνουμε το μη γραμμικό δίκτυο:



Σχήμα 3.16 Μη Γραμμικό Προσαρμοστικό Δίκτυο με Έναν Κόμβο

Οι κόμβοι εκφράζονται ως :

$$x_3 = f_3(x_1, x_2; a_1 a_2 a_3) = a_1 x_1 + a_2 x_2 + a_3$$

$$x_4 = f_4(x_3) = \begin{cases} 1 & \text{if } x_3 \geq 0 \\ 0 & \text{if } x_3 < 0 \end{cases}$$

όπου f_3 είναι μια γραμμική συνάρτηση και f_4 η βηματική συνάρτηση που αντιστοιχεί το x_3 είτε στο 0 είτε στο 1.

Την ολική συνάρτηση του δικτύου μπορούμε να την δούμε σαν ένα γραμμικό ταξινομητή. Ο πρώτος κόμβος σχηματίζει ένα όριο απόφασης σαν


μια ευθεία γραμμή στον χώρο των x_1 - x_2 και ο δεύτερος κόμβος δείχνει σε ποιο ημιεπίπεδο ανήκει το διάνυσμα εισόδου (x_1, x_2) . Επειδή η βηματική συνάρτηση είναι ασυνεχής σε ένα σημείο και επίπεδη σε όλα τα άλλα σημεία, μια εναλλακτική λύση είναι να χρησιμοποιήσουμε της σιγμοειδή συνάρτηση που παίρνει τιμές από 0 έως 1:

$$x_4 = f_4(x_3) = \frac{1}{1 + e^{-x_3}}$$

▪ Πολυεπίπεδο Perceptron

Στο παρακάτω Σχήμα 3.17 βλέπουμε την αρχιτεκτονική για ένα πολυεπίπεδο perceptron με τρεις εισόδους, δυο εξόδους και τρεις κρυμμένους κόμβους που δεν συνδέονται απευθείας ούτε σε είσοδο ούτε σε έξοδο. Κάθε κόμβος σε ένα δίκτυο αυτού του τύπου έχει την ίδια συνάρτηση κόμβου, που είναι σύνθεση μιας γραμμικής f_3 και μιας σιγμοειδούς f_4 . Δηλαδή η συνάρτηση κόμβου στον κόμβο 7 στο παρακάτω Σχήμα 3.17 είναι:

$$x_7 = \frac{1}{1 + \exp[-(w_{4,7}x_4 + w_{5,7}x_5 + w_{6,7}x_6 + t_7)]}$$



Σχήμα 3.17 Πολυεπίπεδο Perceptron

όπου x_4, x_5 και x_6 είναι οι εξοδοί από τους κόμβους 4, 5 και 6 αντίστοιχα και το σύνολο των παραμέτρων του κόμβου 7 δηλώνεται με το $\{w_{4,7}, w_{5,7}, w_{6,7}, t_7\}$. Συνήθως το $w_{i,j}$ είναι το βάρος που σχετίζεται με τον σύνδεσμο που ενώνει τον i -οστό κόμβο και τον j -οστό κόμβο, και το t_j σαν το κατώφλι (threshold) που συνδέεται με τον κόμβο j . Γενικά, ένας σύνδεσμος δείχνει μόνο την κατεύθυνση της ροής σήματος μεταξύ των συνδεδεμένων κόμβων [16].

4^ο ΚΕΦΑΛΑΙΟ



ΜΕΘΟΔΟΣ
ANFIS

ΚΕΦΑΛΑΙΟ 4ο – ΜΕΘΟΔΟΣ ANFIS

4.1 Εισαγωγικά

Η μοντελοποίηση συστήματος που βασίζεται σε συμβατικά μαθηματικά εργαλεία (π.χ. διαφορικές εξισώσεις) δεν είναι κατάλληλη για την αντιμετώπιση ακατάλληλων και αβέβαιων συστημάτων. Αντίθετα, ένα ασαφές σύστημα συμπερασμάτων που χρησιμοποιεί ασαφείς κανόνες αν – τότε μπορεί να μοντελοποιήσει τις ποιοτικές πτυχές της ανθρώπινης γνώσης και τις διαδικασίες συλλογιστικής χωρίς να χρησιμοποιεί ακριβείς ποσοτικές αναλύσεις. Αυτή η ασαφής μοντελοποίηση ή η ασαφής ταυτοποίηση, που εξερευνήθηκε για πρώτη φορά συστηματικά από τους Takagi και Sugeno, έχει βρει πολλές πρακτικές εφαρμογές στον έλεγχο, την πρόβλεψη και το συμπέρασμα. Ωστόσο, υπάρχουν ορισμένες βασικές πτυχές αυτής της προσέγγισης που χρήζουν καλύτερης κατανόησης. Πιο συγκεκριμένα:

- 1) Δεν υπάρχουν τυπικές μέθοδοι για τη μετατροπή της ανθρώπινης γνώσης ή εμπειρίας στη βάση κανόνων και τη βάση δεδομένων ενός συστήματος ασαφούς συμπερασμάτων.
- 2) Υπάρχει ανάγκη για αποτελεσματικές μεθόδους για τον συντονισμό των συναρτήσεων μέλους έτσι ώστε να ελαχιστοποιείται το μέτρο σφάλματος εξόδου ή να μεγιστοποιείται ο δείκτης απόδοσης [25].

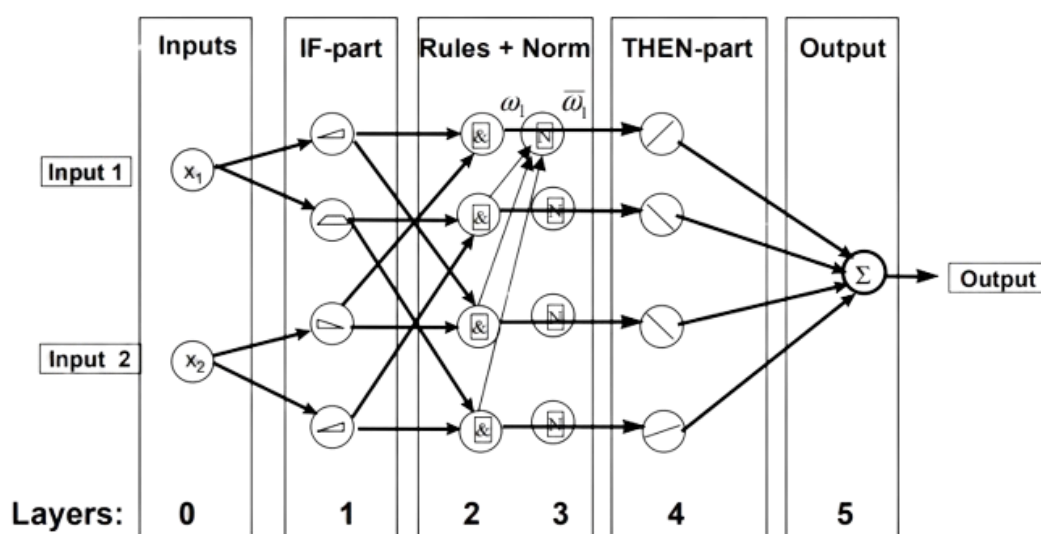
Όπως αναφέρθηκε επιγραμματικά στο 1ο Κεφάλαιο, η μέθοδος ANFIS (Adaptive Neuro – Fuzzy Inference System) αντιπροσωπεύει το Προσαρμοστικό Σύστημα Νευρο – ασαφούς Συμπερασμού και αποτελεί ένα υβριδικό μοντέλο που συνδυάζει δύο ευφυή συστήματα: την μάθηση των Τεχνητών Νευρωνικών Δικτύων (ANN) με τις ικανότητες συλλογισμού της Ασαφούς Λογικής (Fuzzy Logic) και πιο συγκεκριμένα τα Συστήματα Ασαφών Συμπερασμάτων (FISs Fuzzy Inference Systems).

Η μέθοδος ANFIS μπορεί να χρησιμεύσει ως βάση για την κατασκευή ενός συνόλου ασαφών κανόνων αν – τότε, μαζί με κατάλληλες συναρτήσεις μέλους ώστε να δημιουργηθούν τα καθορισμένα ζεύγη εισόδου – εξόδου.

4.2 Δίκτυο ANFIS και Νευρώνες

Στο Σχήμα 4.1 απεικονίζεται ο συλλογιστικό μηχανισμό (reasoning) για το μοντέλο κατά Sugeno και την αντίστοιχη ισοδύναμη αρχιτεκτονική του ANFIS όπου οι κόμβοι του ίδιου επιπέδου έχουν παρόμοιες συναρτήσεις. Παρακάτω παρουσιάζεται πιο αναλυτικά η διεργασία που εκτελείται σε κάθε επίπεδο. Θα πρέπει να σημειωθεί ότι οι νευρώνες στο ANFIS, έχουν διαφορετικές δομές όπως:

- Αξίες - Τιμές (συναρτήσεις συμμετοχής ορισμένες από γενικευμένες συναρτήσεις τύπου Gauss)
- Κανόνες (διαφορίσιμες T - νόρμες συνήθως γινόμενο)
- Κανονικοποίηση (αθροίσματα και αριθμητικές διαιρέσεις)
- Συναρτήσεις (γραμμικές παλινδρομήσεις και πολλαπλασιασμό με σταθμισμένα, κανονικοποιημένα βάρη)
- Αποτέλεσμα (αλγεβρικό άθροισμα)



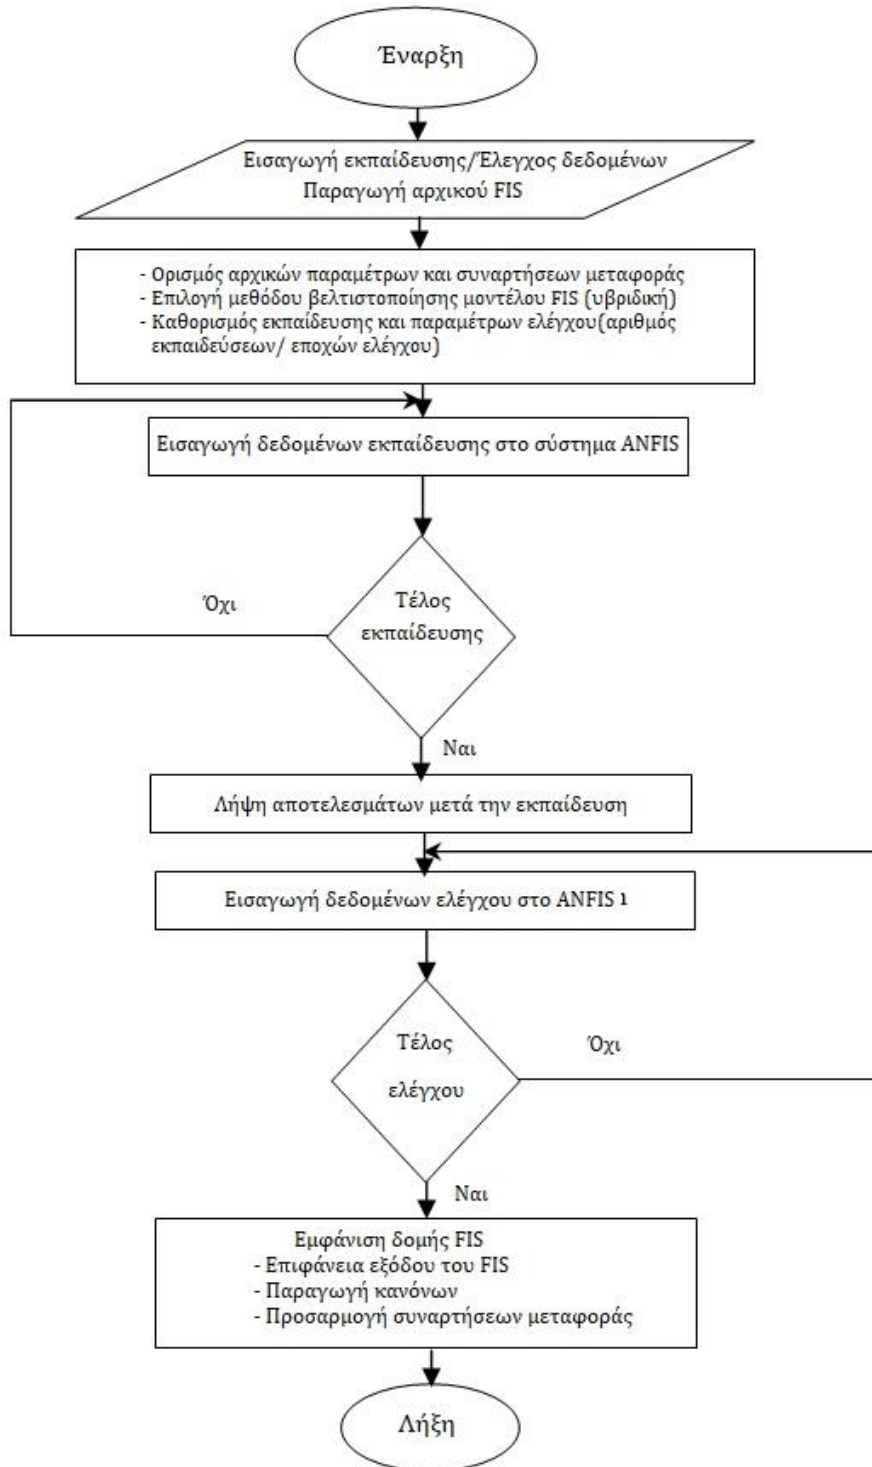
Σχήμα 4.1 Δίκτυο ANFIS

Ο αλγόριθμος ANFIS αναπτύχθηκε για πρώτη φορά το 1992 από τον J.-S. Roger Jang και ουσιαστικά δημιουργεί ένα δέντρο ασαφούς απόφασης ώστε να ταξινομήσει τα δεδομένα σε μοντέλα γραμμικής παλινδρόμησης της μορφής 2^n (ή γενικά p^n) με στόχο τη μείωση του αθροίσματος των τετραγωνισμένων σφαλμάτων. Συγκεκριμένα η Συνολική Τετραγωνική Απόκλιση (SSE - Sum of Squared Errors):

$$SSE = \sum_j e_j^2$$

όπου:

- e_j το σφάλμα ανάμεσα στο επιθυμητό και το πραγματικό αποτέλεσμα
- p ο αριθμός των ασαφών διχοτομήσεων κάθε μεταβλητής
- n ο αριθμός των εισερχόμενων μεταβλητών [26]



Διάγραμμα 4.1 Διάγραμμα Ροής της Μεθόδου Πρόβλεψης Ενός Μοντέλου ANFIS

Παραπάνω, στο Διάγραμμα 4.1, παρουσιάζεται γραφικά η γενική δομή ενός μοντέλου ANFIS μέσω του οποίου παράγονται αποτελέσματα πρόβλεψης. Όπως φαίνεται το μοντέλο αποκτά ένα σύνολο δεδομένων (ζευγάρια εισερχόμενων – εξερχόμενων δεδομένων) και τα χωρίζει σε σύνολα δεδομένων για εκπαίδευση και έλεγχο.

Τα δεδομένα εκπαίδευσης διαμορφώνουν ένα σύνολο διανυσμάτων δεδομένων, εισόδου και εξόδου. Η πληροφορία αυτή κανονικοποιείται ώστε να γίνει κατάλληλη σε μορφή για τη διαδικασία της εκπαίδευσης. Αυτό επιτυγχάνεται προσδίδοντας σε κάθε όρο μία αξία μεταξύ των τιμών 0 και 1 χρησιμοποιώντας τη μέθοδο Max Min. Έπειτα τα κανονικοποιημένα δεδομένα χρησιμοποιούνται ως τιμές εισόδου και εξόδου για να εκπαιδεύσουν το μοντέλο ANFIS. Έτσι δημιουργούνται δύο διανύσματα για την εκπαίδευση του ANFIS: ένα διάνυσμα εισόδου και ένα διάνυσμα εξόδου.

Τα δεδομένα εκπαίδευσης χρησιμοποιούνται για να βρουν τις εισαγωγικές αρχικές παραμέτρους στις συναρτήσεις συμμετοχής. Οι προκύπτουσες παράμετροι υπολογίζονται από τη μέθοδο των ελαχίστων τετραγώνων.


Στη συνέχεια υπολογίζεται ένα σφάλμα για κάθε ζεύγος δεδομένων. Αν το σφάλμα είναι μεγαλύτερο από μία συγκεκριμένη τιμή που έχει θέσει ο ερευνητής, οι εισαγωγικές αρχικές παράμετροι ενημερώνονται μέσω της χρήσης της μεθόδου βαθμωτής καθόδου (gradient decent method), όπως φαίνεται και στον πάνω πίνακα. Η διαδικασία τερματίζεται όταν το σφάλμα γίνει μικρότερο από την καθορισμένη τιμή. Τα βήματα εκπαίδευσης που αναπαριστώνται στον πίνακα, θα εξεταστούν αναλυτικά στην επόμενη ενότητα [24].

4.3 Σχέση Προσαρμοστικών Δικτύων και ANFIS

Το προσαρμοστικό δίκτυο αποτελείται από τους προσαρμοστικούς και τους μη προσαρμοστικούς κόμβους (adaptive, non – adaptive nodes), είναι ένα πολύ – επίπεδο δίκτυο πρόσθιας τροφοδότησης (multi – layer feed – forward network), στο οποίο κάθε κόμβος εκτελεί μία συγκεκριμένη λειτουργία πάνω στα εισερχόμενα σήματα και πάνω στο σύνολο των παραμέτρων που αντιστοιχούν στο συγκεκριμένο κόμβο. Οι κόμβοι συνδέονται μέσω κατευθυντήριων συνδέσμων (directional links). Μερικοί ή όλοι οι κόμβοι είναι προσαρμόσιμοι, γεγονός που οδηγεί στο ότι το αποτέλεσμα καθενός από αυτούς τους κόμβους εξαρτάται από τις παραμέτρους που σχετίζονται με αυτόν τον κόμβο, και ο

κανόνας μάθησης προσδιορίζει πώς αυτοί οι παράμετροι θα πρέπει να μεταβληθούν για την ελαχιστοποίηση ενός προκαθορισμένου μέτρου σφάλματος.

Η λειτουργία του κάθε κόμβου μπορεί να ποικίλει από κόμβο σε κόμβο, και η επιλογή της λειτουργίας ενός κόμβου εξαρτάται από τη συνολική επεξεργασία πάνω στις εισόδους και την έξοδο που το προσαρμοστικό δίκτυο πρέπει να εκτελέσει. Στο παρακάτω Σχήμα 4.2 βλέπουμε τη δομή αυτού του δικτύου όπου οι σύνδεσμοί του απλά υποδεικνύουν την κατεύθυνση της ροής των σημάτων ανάμεσα στους κόμβους, ενώ δεν σχετίζονται με τους συνδέσμους σταθμικά βάρη.



Σχήμα 4.2 Προσαρμοστικό Δίκτυο

Ένας τετράγωνος κόμβος περιλαμβάνει παραμέτρους (adaptive node), ενώ ο κυκλικός κόμβος δεν έχει καμία παράμετρο (fixed node). Το σύνολο των παραμέτρων ενός προσαρμοστικού δικτύου είναι η ένωση των συνόλων των παραμέτρων του κάθε ενός προσαρμοστικού κόμβου. Οι παράμετροι αυτοί ενημερώνονται κατάλληλα, σύμφωνα με δοσμένα δεδομένα εκπαίδευσης και μία gradient based διαδικασία μάθησης, προκειμένου να επιτευχθεί μία επιθυμητή αντιστοίχιση μεταξύ των δεδομένων εισόδου – εξόδου.

Υποτίθεται ότι ένα δοσμένο προσαρμοστικό δίκτυο, αποτελείται από L επίπεδα και το k -οστό επίπεδο έχει (k) κόμβους (nodes). Ο κόμβος μπορεί να συμβολιστεί στην i -οστή θέση του k -οστού επιπέδου με το ζεύγος (k,i) και την αντίστοιχη συνάρτηση του κόμβου (ή αλλιώς έξοδο του κόμβου) με O_i^k . Από τη στιγμή που το αποτέλεσμα ενός κόμβου εξαρτάται από τα εισερχόμενα σήματα και το σύνολο των παραμέτρων του, τότε:

$$O_i^k = O_i^k(O_1^{k-1}, \dots, O_{\#(k-1)}^{k-1}, a, b, c, \dots)$$

όπου a, b, c , κλπ οι παράμετροι που αντιστοιχούν στο συγκεκριμένο κόμβο.

Υποθέτοντας ότι το δοσμένο σύνολο δεδομένων εκπαίδευσης έχει P εισόδους, μπορεί να προσδιοριστεί το μέτρο σφάλματος ως το άθροισμα των τετραγώνων των σφαλμάτων.

$$J_p = \sum_{i=1}^{\#(L)} (T_{i,p} - O_{i,p}^L)^2$$

όπου $T_{i,p}$ είναι το i - οστό συστατικό του p - οστού διανύσματος εξόδων - στόχου που δημιουργείται από την παρουσίαση του p - οστού διανύσματος εισόδου. Επομένως, το μέτρο συνολικού σφάλματος είναι το:

$$J = \sum_{p=1}^P J_p$$

Για να κατασκευαστεί μία διαδικασία μάθησης που εφαρμόζει την μέθοδο βαθμωτής κατάβασης (gradient descent) στο J πάνω στον παραμετρικό χώρο, πρέπει πρώτα να υπολογιστεί το ποσοστό σφάλματος $\partial J_p / \partial O$ για το p - οστό σύνολο δεδομένων εκπαίδευσης. Το ποσοστό σφάλματος για τον κόμβο εξόδου στο (L, i) μπορεί να υπολογιστεί απευθείας από τον παραπάνω τύπο του J_p .

$$\frac{\partial J_p}{\partial O_{i,p}^L} = -2(T_{i,p} - O_{i,p}^L)$$

Για τον εσωτερικό κόμβο στο (k, i) το ποσοστό σφάλματος μπορεί να εξαχθεί από τον κανόνα της αλυσίδας:

$$\frac{\partial J_p}{\partial O_{i,p}^k} = \sum_{m=1}^{\#(k+1)} \frac{\partial J_p}{\partial O_{m,p}^{k+1}} \frac{\partial O_{m,p}^{k+1}}{\partial O_{i,p}^k}$$

όπου $1 \leq k \leq L - 1$. Η προηγούμενη εξίσωση ουσιαστικά συνεπάγεται ότι ο ρυθμός σφάλματος ενός εσωτερικού κόμβου μπορεί να εκφραστεί ως ένας γραμμικός συνδυασμός των ρυθμών σφάλματος των κόμβων του επόμενου επιπέδου. Κατά συνέπεια, για όλα τα $1 \leq k \leq L$ και για $1 \leq i \leq \#(k)$, μπορεί να βρεθεί το $\frac{\partial J_p}{\partial O_{i,p}^k}$ από τις δύο παραπάνω εξισώσεις που μόλις περιγράφηκαν. Αν a είναι μία παράμετρος του δοσμένου προσαρμοστικού δικτύου, τότε:

$$\frac{\partial J_p}{\partial a} = \sum_{O^* \in S} \frac{\partial J_p}{\partial O^*} \frac{\partial O^*}{\partial a} \quad (5.a)$$

όπου S το σύνολο των κόμβων των οποίων τα αποτελέσματα εξαρτώνται από το a . Τότε η παράγωγος του συνολικού σφάλματος J ως προς το a είναι:

$$\frac{\partial J}{\partial a} = \sum_{p=1}^p \frac{\partial J_p}{\partial a} \quad (5.b)$$

Ανάλογα η ενημερωμένη εξίσωση για τη γενικευμένη παράμετρο a είναι:

$$\Delta a = -\eta \frac{\partial J}{\partial a}$$

στην οποία το η είναι ο ρυθμός μάθησης που μπορεί να εκφραστεί και ως:

$$\eta = \frac{k}{\sqrt{\sum a \left(\frac{\partial J}{\partial a} \right)^2}}$$

όπου k είναι το step size, το μέγεθος δηλαδή της κάθε μεταβολής κλίσης στον παραμετρικό χώρο. Συνήθως μπορεί να μεταβληθεί η τιμή του k για να μεταβληθεί η ταχύτητα σύγκλισης.

Υπάρχουν δύο μέθοδοι μάθησης για προσαρμοστικά δίκτυα. Με την off – line learning (batch learning) μέθοδο, ο τρόπος ενημέρωσης των παραμέτρων a βασίζεται στην εξίσωση (5.b) και η ενέργεια ενημέρωσης λαμβάνει χώρα μετά την παρουσίαση του συνόλου των δεδομένων εκπαίδευσης (π.χ. ύστερα από μία περίοδο – epoch). Από την άλλη πλευρά, αν είναι επιθυμητό οι παράμετροι να ενημερωθούν άμεσα ύστερα από την παρουσίαση του κάθε ζευγαριού εισόδων – εξόδων, τότε ο τύπος ενημέρωσης βασίζεται στην εξίσωση (5.a) και αναφέρεται ως μάθηση προτύπου (pattern learning) ή on – line learning.

4.4 Υβριδικός Κανόνας Μάθησης (Hybrid Learning Algorithm) Batch Learning (Off-Line)

Παρά το ότι μπορεί να εφαρμοστεί η βαθμωτή μέθοδος για την αναγνώριση των παραμέτρων σε ένα προσαρμοστικό δίκτυο, η μέθοδος είναι γενικά αργή και πιθανόν να παγιδευτεί σε τοπικά ελάχιστα. Παρακάτω παρουσιάζεται ένας υβριδικός κανόνας μάθησης, που συνδυάζει την βαθμωτή μέθοδο και την εκτίμηση ελαχίστων τετραγώνων (Least Square Error – LSE) για την αναγνώριση των παραμέτρων.

Για απλούστευση υποτίθεται ότι το προσαρμοστικό δίκτυο που εξετάζεται έχει μόνο μία έξοδο:

$$Output = F(\bar{I}, S)$$

όπου \bar{I} είναι το σύνολο των μεταβλητών εισόδου και S είναι το σύνολο των παραμέτρων. Εάν υπάρχει μία συνάρτηση H , τέτοια που η σύνθετη συνάρτηση $H \circ F$ να είναι γραμμική σε κάποια από τα στοιχεία του S , τότε αυτά τα στοιχεία

μπορούν να αναγνωριστούν από τη μέθοδο ελαχίστων τετραγώνων. Με άλλα λόγια, εάν το σύνολο των παραμέτρων S μπορεί να διαχωριστεί σε δύο σύνολα:

$$S = S_1 \oplus S_2$$

τέτοιο ώστε $H \circ F$ να είναι γραμμικό στα στοιχεία του S_2 , τότε εφαρμόζοντας το H στην εξίσωση της εξόδου (output) έχουμε:

$$H(output) = H \circ F(\bar{I}, S)$$

το οποίο είναι γραμμικό ως προς τα στοιχεία του S_2 . Έπειτα, δοσμένων των τιμών των στοιχείων S_1 μπορεί να εισαχθούν τα P δεδομένα εκπαίδευσης στην παραπάνω εξίσωση και να εξαχθεί η παρακάτω εξίσωση πινάκων:

$$AX = B$$

όπου X είναι ένα άγνωστο διάνυσμα, του οποίου τα στοιχεία είναι παράμετροι στο S_2 . Έστω $|S_2| = M$, τότε οι διαστάσεις του A, X και B είναι $P \times M, M \times 1$ και $P \times 1$ αντίστοιχα. Από τη στιγμή που το P (αριθμός των ζευγαριών δεδομένων εκπαίδευσης) είναι συνήθως μεγαλύτερος του M (αριθμός γραμμικών παραμέτρων), αυτό είναι ένα υπερπροσδιορισμένο πρόβλημα και γενικά δεν υπάρχει ακριβής λύση στην παραπάνω εξίσωση πινάκων. Αντίθετα, μία εκτίμηση ελαχίστων τετραγώνων (LSE) του X , έστω X^* , αναζητείται για την ελαχιστοποίηση του τετραγωνικού σφάλματος $\|AX - B\|^2$. Ο πιο γνωστός τύπος για το X^* χρησιμοποιεί την ψευδο-ανάστροφη (pseudo-inverse) λύση του X :

$$X^* = (A^T A)^{-1} A^T B$$

όπου A^T είναι ο ανάστροφος του A , και $(A^T A)^{-1} A^T$ είναι η ψευδοανάστροφη λύση του A , εφόσον $A^T A$ είναι μη μοναδιαίος πίνακας. Η παραπάνω εξίσωση έχει οριστεί με ακρίβεια, αλλά οδηγεί σε χρονοβόρες διαδικασίες κατά τον υπολογισμό αντίστροφων πινάκων και επιπλέον καταλήγει να είναι ακατάλληλα προσδιορισμένη στην περίπτωση που ο $A^T A$ είναι μοναδιαίος πίνακας. Γι' αυτόν το λόγο εφαρμόζονται διαδοχικοί τύποι για τον υπολογισμό της εκτίμησης ελαχίστων τετραγώνων (LSE) του X . Η διαδοχική αυτή μέθοδος της LSE είναι περισσότερο αποτελεσματική (ιδιαίτερα όταν το M είναι μικρό) και μπορεί εύκολα να προσαρμοστεί σε μία on-line εκδοχή για συστήματα με μεταβαλλόμενα χαρακτηριστικά. Συγκεκριμένα, έστω ότι το i -οστό διάνυσμα σειράς του πίνακα A , που προσδιορίζεται στην εξίσωση $AX = B$, είναι a_i^T και το i -οστό στοιχείο του B είναι b_i^T , τότε το X μπορεί να υπολογιστεί επαναληπτικά,

χρησιμοποιώντας κάποιους από τους διαδοχικούς τύπους (sequential formulas) που έχουν χρησιμοποιηθεί ευρύτατα στη βιβλιογραφία (Strobach, 1990).

$$X_{i+1} = X_i + S_i + 1a_i + 1(b_{i+1}^T - a_{i+1}^T X_i)$$

$$S_{i+1} = S_i - \frac{S_i a_{i+1} a_{i+1}^T S_i}{1 + a_{i+1}^T S_i a_{i+1}}, \quad i = 0, 1, \dots, P - 1$$

όπου S_i αποκαλείται συνήθως πίνακας συνδιακύμανσης (covariance matrix) και η εκτίμηση ελαχίστων τετραγώνων X^* είναι ίση με X_p . Οι αρχικές συνθήκες στην παραπάνω bootstrap εξίσωση είναι $X_0 = 0$ και $S_0 = \gamma I$, όπου γ είναι ένας θετικός μεγάλος αριθμός και I είναι ο ταυτοτικός πίνακας (identity matrix) διάστασης $M \times M$. Σε περίπτωση προσαρμοστικού δικτύου πολλαπλών εξόδων, η παραπάνω εξίσωση διατηρεί την ισχύ της, με τη διαφορά ότι b_i^T είναι οι i -οστές σειρές του πίνακα B . Τώρα μπορεί να συνδυαστεί η βαθμωτή μέθοδος με την εκτίμηση ελαχίστων τετραγώνων για να ενημερωθούν οι παράμετροι του δικτύου. Κάθε περίοδος της υβριδικής διαδικασίας μάθησης αποτελείται από πέρασμα προς τα εμπρός (forward pass) και από ένα πέρασμα προς τα πίσω (backward pass). Στο πέρασμα προς τα εμπρός τροφοδοτούνται τα δεδομένα εισόδου και τα λειτουργικά σήματα (functional signals) προωθούνται για τον υπολογισμό του αποτελέσματος κάθε κόμβου, μέχρι οι πίνακες A και B στην εξίσωση $AX = B$ να προκύψουν και οι παράμετροι στο S_2 να αναγνωριστούν από τους διαδοχικούς τύπους ελαχίστων τετραγώνων στην παραπάνω εξίσωση. Έπειτα από την αναγνώριση των παραμέτρων στο S_2 , τα λειτουργικά σήματα συνεχίζουν την πορεία τους, μέχρι το μέτρο σφάλματος να υπολογιστεί. Στο πέρασμα προς τα πίσω τα ποσοστά σφάλματος μεταδίδονται από την έξοδο προς την είσοδο και οι παράμετροι στο S_1 ενημερώνονται με βάση την βαθμωτή μέθοδο στην εξίσωση:

$$\Delta a = -\eta \frac{\partial J}{\partial a}$$

Επομένως, για δοσμένες σταθερές τιμές των παραμέτρων στο S_1 , οι παράμετροι που προκύπτουν στο S_2 είναι εγγυημένα το ολικά βέλτιστο σημείο στον S_2 στον παραμετρικό χώρο, λόγω της επιλογής του μέτρου του τετραγωνικού σφάλματος. Ο υβριδικός αυτός κανόνας μάθησης κατορθώνει όχι μόνο να μειώσει τη διάσταση του χώρου αναζήτησης στην gradient μέθοδο, αλλά και να μειώσει σημαντικά το χρόνο σύγκλισης.

Λαμβάνοντας υπόψη ένα παράδειγμα ενός κρυμμένου επιπέδου ενός νευρωνικού δικτύου οπισθόδρομης διάδοσης με σιγμοειδείς συναρτήσεις ενεργοποίησης το οποίο να έχει p μονάδες εξόδου, τότε το αποτέλεσμα στην εξίσωση $Output = F(\bar{I}, S)$ είναι ένα διάνυσμα στήλη. Έστω $H(\cdot)$ η αντίστροφη σιγμοειδής συνάρτηση:

$$H(x) = \ln\left(\frac{x}{1-x}\right)$$

τότε η εξίσωση $H(Output) = H \circ F(\bar{I}, S)$ καταλήγει μια γραμμική συνάρτηση τέτοια που κάθε στοιχείο του $H(Output)$ αποτελεί έναν γραμμικό συνδυασμό των παραμέτρων (βαρών και κατωφλιών) που αφορούν το επίπεδο 2. Με άλλα λόγια:

S_1 = Βάρη και κατώφλια του κρυμμένου επιπέδου

S_2 = Βάρη και κατώφλια του επιπέδου εξόδου

Κατά συνέπεια, μπορεί να εφαρμοστεί ο κανόνας μάθησης οπισθόδρομης μετάδοσης του σφάλματος (back propagation learning rule) για το συντονισμό των παραμέτρων στο κρυμμένο επίπεδο και οι παράμετροι στο επίπεδο εξόδου μπορούν να προσδιοριστούν με τη μέθοδο ελαχίστων τετραγώνων. Πάντως, θα πρέπει να σημειωθεί ότι χρησιμοποιώντας τη μέθοδο ελαχίστων τετραγώνων στα δεδομένα που τροποποιούνται από την $H(\cdot)$, οι αποκτηθείσες παράμετροι είναι βέλτιστες σε όρους του μετασχηματισμένου μέτρου τετραγωνικού σφάλματος σε αντίθεση με τον αντίστοιχο αρχικό. Συνήθως αυτό δεν προκαλεί κάποιο πρακτικό πρόβλημα από τη στιγμή που το $H(\cdot)$ αυξάνεται μονοτονικά.

4.5 Σχέση Μεταξύ ANFIS και Ασαφούς Μοντέλου Takagi – Sugeno – Kang (TSK)

Το ασαφές μοντέλο Takagi – Sugeno – Kang (TSK), παρουσιάστηκε στην ενότητα 3.7. Στην γενική του μορφή το μοντέλο αυτό αναπτύσσει μια συστηματική μέθοδο δημιουργίας ασαφών κανόνων από ένα δοθέν σύνολο δεδομένων. Η τυπική μορφή ενός ασαφούς κανόνα στο μοντέλο αυτό είναι της μορφής:

$$\text{εάν } x_1 \text{ είναι } A_1 \text{ και } \dots \text{ και } x_N \text{ είναι } A_n \text{ τότε } y = f(x_1, \dots, x_N)$$

όπου τα A_n , $n = 1, \dots, N$ απεικονίζουν τις ασαφείς τιμές των αιτίων (ασαφή σύνολα εισόδου). Η σημαντικότερη ειδοποιός διαφορά του μοντέλου αυτού βρίσκεται στη συναρτησιακή μορφή του αποτελέσματος σε αντιδιαστολή με το

ασαφές αποτέλεσμα που δίδεται από το μοντέλο Mamdani. Συνήθως η συνάρτηση f είναι πολυωνυμική στις μεταβλητές εισόδου x_k , δηλαδή ισχύει:

$$f(x_1, \dots, x_N) = p_1 x_1 + \dots + p_N x_N + p_0$$

Για ένα σύνολο m ασαφών κανόνων, το συμπερασματικό μοντέλο υπολογίζει μια έξοδο συνεχούς τιμής y εκφρασμένη ως σταθμισμένο μέσο όρο (weighted average) των επιμέρους εξόδων $y_i = (i = 1, \dots, m)$

$$y = \sum_{i=1}^m \frac{w_i y_i}{\sum_{j=1}^m w_j} = \sum_{i=1}^m \frac{w_i}{\sum_{j=1}^m w_j} (p_i x_i + \dots + p_{iN} x_N + p_{i0})$$

όπου το w_i εκφράζει την ισχύ του κανόνα i ($w_i = \mu_{Ai1}(x) \wedge \dots \wedge \mu_{AiN}(x_N)$). Από γεωμετρικής άποψης, το σύνολο των κανόνων του μοντέλου Sugeno παρουσιάζει μια προσέγγιση της απεικόνισης $X_1 \times \dots \times X_N \rightarrow Y$ με μία τμηματικά (piecewise) γραμμική συνάρτηση (γενικά όμως η συνάρτηση μπορεί να είναι και μη γραμμική). Το ασαφές μοντέλο Sugeno προσφέρει ένα μεγάλο πλεονέκτημα σχετικά με την περιγραφή πολύπλοκων συστημάτων ελέγχου, επιτρέποντας τη διάσπαση ενός συστήματος σε μικρότερα υποσυστήματα και επιπλέον το διαμερισμό του χώρου εισόδου.

Το Sugeno ασαφές μοντέλο είναι το μοντέλο που χρησιμοποιείται στο εκπαιδευόμενη ασαφούς λογικής δίκτυο ANFIS. Το ANFIS είναι μία συστηματοποιημένη προσπάθεια παραγωγής κανόνων της μορφής εάν – τότε από ζευγάρια εισόδου – εξόδου. Ένα τυπικό μοντέλο Sugeno έχει τη μορφή:

$$\text{εάν } x \text{ είναι } A \text{ και } y \text{ είναι } B \text{ τότε } z = f(x, y).$$

Ο τρόπος με τον οποίο συνδυάζονται οι μεταβλητές x και y συνοψίζεται στα εξής:

Αν $x \in A, y \in B$ τότε η σχέση x είναι A και y είναι B μεταφράζεται στην ασαφή σχέση $A \cap B$ στο $U \times V$ με συνάρτηση συμμετοχής

$$\mu_{A \cap B}(x) = t[\mu_A(x) \mu_B(x)],$$

όπου t είναι ουσιαστικά η προβολή $t: [0,1] \times [0,1] \rightarrow [0,1]$. Όσον αφορά την τιμή z , όταν η $f(x, y)$ είναι πολυώνυμο πρώτου βαθμού (έχει δηλαδή τη μορφή $z_1 = p_1 x + q_1 y + r_1$), τότε ονομάζεται Sugeno μοντέλο πρώτης τάξης. Αν η $f(x, y)$ είναι πραγματικός αριθμός, τότε ονομάζεται Sugeno μοντέλο μηδενικής τάξης. Ουσιαστικά, όταν το μοντέλο είναι μηδενικής τάξης έχουμε σχεδόν ένα δίκτυο RBF (Radial Basis Function)[27].


4.6 Αρχιτεκτονική του ANFIS

Ο αλγόριθμος ANFIS είναι από τους κυριότερους αλλά και ταυτόχρονα από τους πρώτους που εφαρμόστηκαν στο πεδίο της νευροασαφούς προσέγγισης προβλημάτων. Παρακάτω περιγράφεται το δίκτυο, υποθέτοντας ότι το πρόβλημα το οποίο θα αναλυθεί έχει δύο εισόδους x και y και μία έξοδο z . Υποθέτοντας ότι για ένα πρώτης τάξης μοντέλο Sugeno, μία τυπική βάση κανόνων (rule base) θα μπορούσε να είναι και η εξής:

Κανόνας 1: Εάν f_x είναι A_1 και y είναι B_1 τότε $f_1 = p_1 \times x + q_1 \times y + r_1$

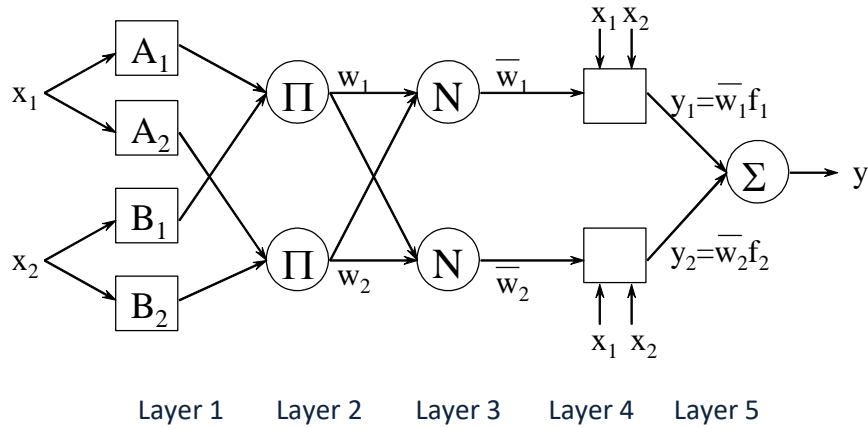
Κανόνας 2: Εάν f_x είναι A_2 και y είναι B_2 τότε $f_2 = p_2 \times x + q_2 \times y + r_2$

Το παρακάτω Σχήμα 4.3 δείχνει με απλό τρόπο τη διαδικασία συμπερασμού (inference procedure) του μοντέλου Sugeno, στην περίπτωση όπου για t -operator έχει επιλεγεί η τομή των δύο ασαφών συνόλων (A,B) , οπότε $\mu_{A \cap B}(x) = \min[\mu_A(x), \mu_B(x)]$.



Σχήμα 4.3 Ασαφής Συλλογιστική (Fuzzy Reasoning)

Όπως γίνεται φανερό, η έξοδος z του πρωτοβάθμιου μοντέλου Sugeno είναι ένας σταθμικός μέσος όρος. Η αντίστοιχη αναπαράσταση του δικτύου ANFIS παρουσιάζεται στο παρακάτω Σχήμα 4.4.



Σχήμα 4.4 Η Αρχιτεκτονική Δομή του ANFIS

Οι παράμετροι οι οποίοι προσαρμόζονται μέσω της εκπαίδευσης είναι:

1. **Οι παράμετροι της υπόθεσης των κανόνων (premise parameters)**, οι οποίες είναι μη γραμμικές και εμφανίζονται στις συναρτήσεις συμμετοχής των εισόδων, στο πρώτο επίπεδο, με τη μορφή των κέντρων (centers, c) και των πλατών (widths, σ), των συναρτήσεων συμμετοχής.
2. **Οι παράμετροι της απόδοσης των κανόνων (consequent parameters)**, οι οποίες είναι γραμμικές και εμφανίζονται στο τέταρτο επίπεδο, με τη μορφή βαρών (weights, w) των εξόδων.

Ο κάθε κόμβος και το κάθε επίπεδο του ANFIS έχει μία ιδιαίτερη χρήση, η οποία εξηγείται παρακάτω.

Επίπεδο 1: Κάθε κόμβος i σε αυτό το επίπεδο συμπεριφέρεται όπως οι νευρώνες στα νευρωνικά δίκτυα, δηλαδή λειτουργούν ως συναρτήσεις μεταφοράς. Είναι ένας προσαρμόσιμος (adaptive) κόμβος με μία συνάρτηση κόμβου:

$$O_{1,i} = \mu_{A_i}(x_1) \text{ για } i=1,2 \text{ ή}$$

$$O_{1,i} = \mu_{B_{i-2}}(x_2) \text{ για } i=3,4$$

Όπου x , η είσοδος στον κόμβο i , A_i (ή B_{i-2}) είναι η γλωσσική μεταβλητή (πολύ μικρό, μικρό, μέτριο, μεγάλο και πολύ μεγάλο) που σχετίζεται με αυτή τη συνάρτηση του κόμβου. Το $O_{1,i}$ είναι ο βαθμός συμμετοχής του $A(=A_1, A_2, B_1 \text{ ή } B_2)$ και καθορίζει το βαθμό στον οποίο η είσοδος x ικανοποιεί ένα τμήμα του κανόνα. Η συνάρτηση συμμετοχής του A είναι τύπου gaussmf:

$$\text{gaussmf}(x, c, \sigma) = e^{-\frac{1}{2}\left(\frac{x-c}{\sigma}\right)^2}$$

όπου c, σ είναι το σύνολο των παραμέτρων. Καθώς οι τιμές αυτών των παραμέτρων αλλάζουν, η γκαουσιανή συνάρτηση συμμετοχής αλλάζει ανάλογα, παρουσιάζοντας έτσι διάφορες μορφές της συνάρτησης συμμετοχής για το ασαφές σύνολο A . Οι παράμετροι σε αυτό το επίπεδο αναφέρονται ως παράμετροι υπόθεσης. Στον κόμβο αυτό γίνεται η ασαφοποίηση των τιμών των εισόδων (fuzzification).

Επίπεδο 2: Κάθε κόμβος σε αυτό το επίπεδο είναι ένας σταθερός (fixed) κόμβος Π , του οποίου η έξοδος είναι το γινόμενο όλων των εισερχόμενων σημάτων:

$$O_{2,1} = w_1 = \mu_{A_1}(x_1) \times \mu_{B_1}(x_2)$$

$$O_{2,2} = w_2 = \mu_{A_2}(x_1) \times \mu_{B_2}(x_2)$$

Πρέπει να αναφέρουμε ότι εκτός του γινομένου μπορεί να χρησιμοποιηθεί οποιαδήποτε πράξη από τις αποδεκτές της ασαφούς λογικής που υλοποιούν την πράξη AND.

Επίπεδο 3: Κάθε κόμβος σε αυτό το επίπεδο είναι ένας σταθερός (fixed) κόμβος N . Ο i -οστός κόμβος υπολογίζει απλώς το πηλίκο της ισχύος του i -κανόνα ως προς το άθροισμα όλων των άλλων, δηλαδή τον βαθμό ενεργοποίησης (firing strength) του i -οστού κανόνα στο άθροισμα των βαθμών ενεργοποίησης όλων των κανόνων:

$$O_{3,i} = \overline{w}_i = \frac{w_i}{w_1 + w_2}, \text{ για } i = 1, 2$$

Οι έξοδοι αυτού του επιπέδου ονομάζονται κανονικοποιημένοι βαθμοί ενεργοποίησης (normalized firing strengths).

Επίπεδο 4: Κάθε κόμβος i σε αυτό το επίπεδο υπόκειται στη διαδικασία μάθησης. Είναι ένας προσαρμόσιμος (adaptive) κόμβος με μία συνάρτηση κόμβου:

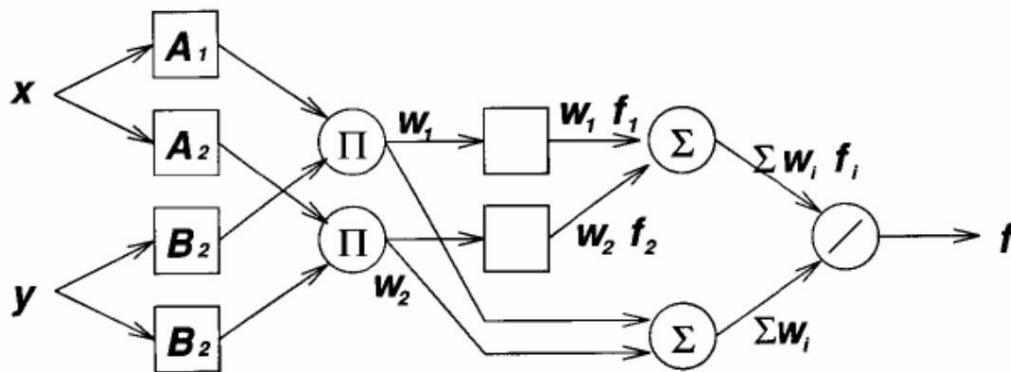
$$O_{4,i} = \overline{w}_i \times f_i = \overline{w}_i \times (p_i \times x_1 + q_i \times x_2 + r_i)$$

όπου: \overline{w}_i είναι η έξοδος του επιπέδου 3 (ο βαθμός ενεργοποίησης) και $\{p_i, q_i, r_i\}$ είναι το σύνολο παραμέτρων αυτού του κόμβου, οι οποίες παράμετροι σε αυτό το επίπεδο υπόκεινται σε εκπαίδευση και αναφέρονται ως παράμετροι απόδοσης του κάθε κανόνα (consequent parameters).

Επίπεδο 5: Ο μοναδικός κόμβος σε αυτό το επίπεδο είναι ένας σταθερός (fixed) κόμβος Σ , που υπολογίζει τη συνολική έξοδο σαν το ολικό άθροισμα όλων των εισερχόμενων σημάτων:

$$\text{overall output} = O_{5,i} = \sum_i \bar{w}_i \times f_i = \frac{\sum_i w_i \times f_i}{\sum_i w_i} \quad [27]$$

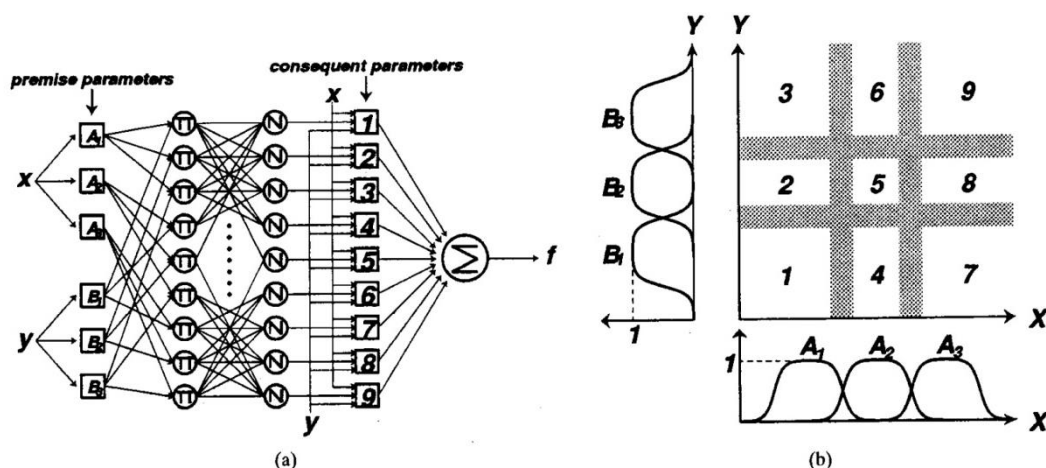
Αυτό το προσαρμοστικό δίκτυο είναι λειτουργικά ισοδύναμο με το ασαφές μοντέλο Sugeno. Μπορούμε να συνδυάσουμε τα επίπεδα 3 και 4 για να αποκτήσουμε ένα ισοδύναμο δίκτυο με τέσσερα μόνο επίπεδα. Με το ίδιο δείγμα μπορούμε να πραγματοποιήσουμε την κανονικοποίηση των βαρών στο τελευταίο επίπεδο. Το Σχήμα 5.5 απεικονίζει ένα ANFIS αυτού του τύπου. Στην ακραία περίπτωση μπορούμε να συρρικνώσουμε ακόμα και όλο το δίκτυο, σε έναν μόνο προσαρμοστικό κόμβο με το ίδιο σύνολο παραμέτρων. Η ανάθεση συναρτήσεων κόμβων και η σύνθεση του δικτύου είναι αυθαίρετες, εφόσον κάθε κόμβος και κάθε επίπεδο πραγματοποιούν λειτουργίες που είναι σημαντικές και έχουν δυνατότητα να αποτελούνται από επιμέρους τμήματα.



Σχήμα 4.5 Η Αρχιτεκτονική του ANFIS για το Ασαφές Σύνολο Sugeno - Κανονικοποίηση στο Τελευταίο Επίπεδο

Εκτός από το μηχανισμό συμπερασμού του Sugeno, μπορούμε να κατασκευάσουμε ANFIS και με το μοντέλο Mamdani. Το Sugeno χρησιμοποιείται περισσότερο συχνά, μιας και διακρίνεται για την διαφάνεια και την αποτελεσματικότητά του. Στο Σχήμα 4.6 (a) βλέπουμε μια αρχιτεκτονική ANFIS που είναι ισοδύναμη με ένα ασαφές μοντέλο Sugeno πρώτου βαθμού δυο εισόδων και εννέα κανόνων, σε κάθε είσοδο θεωρούμε ότι αντιστοιχούν τρεις συναρτήσεις συμμετοχής. Το Σχήμα 4.6 (b) απεικονίζει πως δύο διαστάσεων χώρος εισόδου είναι χωρισμένος σε εννέα υπέρθετες (overlapping) ασαφείς

περιοχές όπου κάθε μια ελέγχεται από ένα ασαφή κανόνα if – then. Αυτό σημαίνει ότι το μέρος των προϋποθέσεων ενός κανόνα προσδιορίζει μια ασαφή περιοχή, ενώ το μέρος των συμπερασμάτων προσδιορίζει την έξοδο μέσα στην περιοχή [28].



Σχήμα 4.6 (a) Η αρχιτεκτονική του ANFIS για το ασαφές μοντέλο κατά Sugeno με δύο εισόδους και εννέα κανόνες (b) ο χώρος εισόδου, χωρισμένος σε εννέα ασαφείς περιοχές

4.7 Εκτιμητής Ελαχίστων Τετραγώνων (Least – Squares Estimator)

Το ANFIS χρησιμοποιεί έναν υβριδικό αλγόριθμο εκμάθησης για να προσδιορίσει τις παραμέτρους του ασαφούς συστήματος τύπου Sugeno. Εφαρμόζει έναν συνδυασμό της μεθόδου ελαχίστων τετραγώνων (least – squares) και της μεθόδου οπισθόδρομης βαθμωτής ελαχιστοποίησης (back – propagation gradient descent) για την εκπαίδευση παραμέτρων των συναρτήσεων συμμετοχής του FIS ώστε να μιμηθεί ένα δοσμένο σύνολο δεδομένων εκπαίδευσης.

Στο γενικό πρόβλημα ελαχίστων τετραγώνων, η έξοδος του γραμμικού μοντέλου y δίνεται από τη γραμμικά παραμετροποιημένη έκφραση:

$$y = \theta_1 f_1(u) + \theta_2 f_2(u) + \dots + \theta_n f_n(u)$$

όπου $u = [u_1, \dots, u_p]^T$ είναι το διάνυσμα εισόδου του μοντέλου, f_1, \dots, f_n είναι οι γνωστές συναρτήσεις του u και $\theta_1, \dots, \theta_n$ είναι άγνωστες παράμετροι που θα υπολογιστούν. Η παραπάνω εξίσωση καλείται συνάρτηση παλινδρόμησης και τα θ_i ονομάζονται συντελεστές παλινδρόμησης.

Για να προσδιοριστούν οι άγνωστες παράμετροι θ_i , συνήθως πρέπει να εκτελεστούν πειράματα για να βρεθεί ένα σύνολο δεδομένων εκπαίδευσης που αποτελείται από τα ζευγάρια δεδομένων $\{(u_i, y_i), i = 1, \dots, m\}$ τα οποία αντιπροσωπεύουν τα επιθυμητά ζευγάρια εισόδου – εξόδου του συστήματος

στόχου που θα μοντελοποιηθεί. Η αντικατάσταση κάθε ζευγαριού στοιχείων σε αυτήν την εξίσωση παράγει ένα σύνολο γραμμικών εξισώσεων m :

$$f_1(u_1)\theta_1 + f_2(u_1)\theta_2 + \dots + f_n(u_1)\theta_n = y_1$$

$$f_1(u_2)\theta_1 + f_2(u_2)\theta_2 + \dots + f_n(u_2)\theta_n = y_2$$

...

$$f_1(u_n)\theta_1 + f_2(u_n)\theta_2 + \dots + f_n(u_n)\theta_n = y_n$$

Σε μορφή πινάκων, οι προηγούμενες εξισώσεις μπορούν να γραφτούν σε συνοπτική μορφή:

$$A\theta = y$$

όπου A είναι ένας $m \times n$ πίνακας (πίνακας σχεδιασμού):

$$A = \begin{bmatrix} f_1(u_1) & \dots & f_n(u_1) \\ \vdots & \ddots & \vdots \\ f_1(u_m) & \dots & f_n(u_m) \end{bmatrix}$$

θ είναι ένα $n \times 1$ διάνυσμα άγνωστων παραμέτρων και y είναι ένα $m \times 1$ διάνυσμα εξόδου:

$$\theta = \begin{bmatrix} \theta_1 \\ \vdots \\ \theta_n \end{bmatrix} \quad y = \begin{bmatrix} y_1 \\ \vdots \\ y_n \end{bmatrix}$$

Η i -οστή σειρά του ενωμένου πίνακα δεδομένων $[A \ y]$, που δηλώνεται με $[a_i^T : y_i]$, σχετίζεται με το i -οστό ζευγάρι δεδομένων (u_i, y_i) μέσω της:

$$a_i^T = [f_1(u_i), \dots, f_n(u_i)] \quad (5.c)$$

Το μεγαλύτερο μέρος των υπολογισμών βασίζεται στους πίνακες A και y , μερικές φορές γίνεται αναφορά στο $[a_i^T; y_i]$, σαν το i -οστό ζευγάρι δεδομένων του συνόλου δεδομένων εκπαίδευσης. Για να προσδιοριστεί μεμονωμένα το άγνωστο διάνυσμα θ , είναι απαραίτητο να ισχύει $m \geq n$. Αν ο A είναι τετραγωνικός ($m = n$) τότε η παραπάνω εξίσωση (5.c) μπορεί να λυθεί ως προς τον άγνωστο x και γίνεται:

$$\theta = A^{-1}y$$

Ο m είναι συνήθως μεγαλύτερος από τον n , που σημαίνει ότι υπάρχουν περισσότερα ζευγάρια στοιχείων από τις παραμέτρους. Σε αυτήν την περίπτωση, μια ακριβής λύση που να ικανοποιεί όλες τις m εξισώσεις δεν είναι πάντα δυνατή, δεδομένου ότι τα στοιχεία μπορεί να μολυνθούν από θόρυβο, ή το μοντέλο μπορεί να μην είναι κατάλληλο για την περιγραφή του συστήματος στόχου.

Κατά συνέπεια η εξίσωση (5.c) πρέπει να τροποποιηθεί με την ενσωμάτωση ενός διανύσματος λάθους e για να αποτελέσει το τυχαίο λάθος θορύβου ή το τυχαίο λάθος διαμόρφωσης ως εξής:

$$A\theta + e = y$$

Τώρα, αντί της εύρεσης της ακριβούς λύσης στην εξίσωση (5.c), πρέπει να βρεθεί το $\theta = \hat{\theta}$ που ελαχιστοποιεί το άθροισμα του τετραγωνικού σφάλματος και ορίζεται ως εξής:

$$E(\theta) = \sum_{i=1}^m (y_i - a_i^T \theta)^2 = e^T e = (y - A\theta)^T (y - A\theta)$$

όπου $e = y - A\theta$ είναι το διάνυσμα λάθους που παράγεται από μια συγκεκριμένη επιλογή του θ . Πρέπει να σημειωθεί ότι το $E(\theta)$ είναι σε τετραγωνική μορφή και έχει ένα μοναδικό ελάχιστο $\theta = \hat{\theta}$. Το ακόλουθο θεώρημα δηλώνει έναν απαραίτητο όρο που ικανοποιείται από τον εκτιμητή ελαχίστων τετραγώνων $\hat{\theta}$.

Εκτιμητής Ελαχίστων Τετραγώνων

Το τετραγωνικό σφάλμα στην εξίσωση (5.c) ελαχιστοποιείται όταν $\theta = \hat{\theta}$, ο οποίος καλείται εκτιμητής ελαχίστων τετραγώνων (LSE) και ο οποίος ικανοποιεί την κανονική εξίσωση:

$$A^T A \theta = A^T y$$

Αν ο $A^T A$ είναι μοναδικός και δίνεται από την:

$$\hat{\theta} (A^T A)^{-1} A^{-T} y$$

4.8 Οπισθόδρομη Εκμάθηση για Έμπροσθεν - Τροφοδοτούμενα Δίκτυα (ANFIS)

Η ενότητα αυτή παρουσιάζει ένα βασικό κανόνα εκμάθησης για προσαρμόσιμα δίκτυα, που είναι στην ουσία η πιο απλή μέθοδος βαθμωτής ελαχιστοποίησης. Το κεντρικό μέρος αυτού του κανόνα εκμάθησης αφορά στο πως να επιλεγεί επαναληπτικά ένα διάνυσμα κλίσης στο οποίο κάθε στοιχείο ορίζεται ως την παράγωγο ενός μέτρου σφάλματος ως προς μια παράμετρο. Αυτό γίνεται με τη βοήθεια του κανόνα αλυσίδας, ενός βασικού τύπου για το διαφορισμό σύνθετων συναρτήσεων ο οποίος αναλύεται σε κάθε εγχειρίδιο μαθηματικών. Η διαδικασία εύρεσης ενός διανύσματος κλίσης σε ένα δίκτυο αναφέρεται γενικά σαν οπισθοδρόμηση (backpropagation) επειδή το διάνυσμα

κλίσης υπολογίζεται σε κατεύθυνση αντίθετη από τη ροή της εξόδου κάθε κόμβου. Μόλις επιλεγεί η κλίση, διάφορες τεχνικές βελτιστοποίησης και παλινδρόμησης βασισμένες στις παραγώγους είναι διαθέσιμες για την ενημέρωση των παραμέτρων. Ειδικότερα, εάν χρησιμοποιούμε το διάνυσμα κλίσης σε μια απλή μέθοδο βαθμωτής ελαχιστοποίησης, το προκύπτον παράδειγμα εκμάθησης αναφέρεται συχνά ως κανόνας οπισθόδρομης εκμάθησης.

Έστω ότι δεδομένο πρωτο-τροφοδοτούμενο προσαρμόσιμο δίκτυο στην αναπαράστασή του σε επίπεδα έχει L επίπεδα και το επίπεδο l (όπου $l = 0, 1, \dots, L$; $l = 0$ αντιπροσωπεύει το επίπεδο εισαγωγής) έχει $N(l)$ κόμβους. Τότε η έξοδος και η συνάρτηση του κόμβου i [$i = 1, \dots, N(l)$] στο επίπεδο l μπορούν να αναπαρασταθούν σαν $x_{l,i}$ και $f_{l,i}$, αντίστοιχα. Ας υποτεθεί ότι δεν υπάρχει καμία σύνδεση μεταξύ μη συνεχόμενων στρωμάτων. Δεδομένου ότι η έξοδος ενός κόμβου εξαρτάται από τα εισερχόμενα σήματα και το σύνολο παραμέτρων του κόμβου, προκύπτει η ακόλουθη γενική έκφραση για τη συνάρτηση των κόμβων $f_{l,i}$:

$$x_{l,i} = f_{l,i}(x_{l-1,1}, \dots, x_{l-1,N(l-1)}, \alpha, \beta, \gamma, \dots)$$

όπου α, β, γ , κλπ. είναι οι παράμετροι αυτού του κόμβου.


Υποθέτοντας ότι το δοσμένο σύνολο δεδομένων εκπαίδευσης έχει P καταχωρήσεις, μπορεί να οριστεί ένα μέτρο σφάλματος για την p -οστή ($1 \leq p \leq P$) καταχώρηση των δεδομένων εκπαίδευσης σαν το άθροισμα των τετραγωνικών σφαλμάτων:

$$E_p = \sum_{k=1}^{N(l)} (d_k - x_{l,k})^2$$

όπου d_k είναι το k -οστό συστατικό του p -οστού επιθυμητού διανύσματος εξόδου και $x_{l,k}$ είναι το k -οστό συστατικό του πραγματικού διανύσματος εξόδου που παράγεται με την παρουσίαση του p -οστού διανύσματος εισόδου στο δίκτυο. Προφανώς, όταν το E_p είναι ίσο με το μηδέν, το δίκτυο είναι ικανό να αναπαράγει ακριβώς το επιθυμητό διάνυσμα εξόδου στο p -οστό ζευγάρι δεδομένων εκπαίδευσης. Ο στόχος εδώ είναι να ελαχιστοποιηθεί ένα συνολικό μέτρο σφάλματος, που ορίζεται ως:

$$E = \sum_{p=1}^p E_p$$

Επιπλέον, ας υποτεθεί ότι το E_p εξαρτάται μόνο από τους κόμβους εξόδου. Για να χρησιμοποιηθεί η βαθμωτή ελαχιστοποίηση ώστε να ελαχιστοποιηθεί το μέτρο σφάλματος, πρέπει πρώτα να βρεθεί το διάνυσμα κλίσης. Πριν υπολογιστεί το διάνυσμα κλίσης, πρέπει να παρατηρηθούν οι ακόλουθες αιτιώδεις σχέσεις:



όπου τα βέλη \Rightarrow δείχνουν τις αιτιώδεις σχέσεις. Δηλαδή, μια μικρή αλλαγή σε μια παράμετρο α θα επηρεάσει την έξοδο του κόμβου που περιέχει το α . Αυτό με τη σειρά του θα επηρεάσει την έξοδο του τελευταίου επιπέδου και συνεπώς το μέτρο σφάλματος. Η βασική αρχή στον υπολογισμό του διανύσματος κλίσης είναι να περαστούν μια σειρά από πληροφορίες παραγώγων ξεκινώντας από το επίπεδο εξόδου και πηγαίνοντας ανάποδα από επίπεδο σε επίπεδο έως ότου καταλήξει η διαδικασία στο επίπεδο εισόδου.

Το σήμα σφάλματος $e_{l,i}$ ορίζεται σαν τη παράγωγο του μέτρου σφάλματος E_p ως προς την έξοδο του κόμβου i στο επίπεδο l , λαμβάνοντας υπόψη και τις άμεσες και τις έμμεσες πορείες.

$$e_{l,i} = \frac{\partial^+ E_p}{\partial x_{l,i}}$$

Η έκφραση αυτή ονομάστηκε διατεταγμένη παράγωγος από τον Werbos. Το σήμα σφάλματος για τον i -οστό κόμβο εξόδου (στο επίπεδο L) μπορεί να υπολογιστεί απευθείας:

$$e_{l,i} = \frac{\partial^+ E_p}{\partial x_{l,i}} = \frac{\partial E_p}{\partial x_{l,i}}$$

Αυτό ισούται με $e_{L,i} = -2(d_i - x_{L,i})$ αν το E_p ορίζεται όπως προηγουμένως. Για τον εσωτερικό κόμβο στην i -οστή θέση του επιπέδου l , το σήμα σφάλματος μπορεί να βρεθεί από τον κανόνα αλυσίδας:

$$e_{l,i} = \underbrace{\frac{\partial^+ E_p}{\partial x_{l,i}}}_{\text{}} = \sum_{m=1}^{N(l+1)} \underbrace{\frac{\partial^+ E_p}{\partial x_{l+1,m}}}_{\text{}} \frac{\partial f_{l+1,m}}{\partial x_{l,i}} = \sum_{m=1}^{N(l+1)} e_{l+1,m} \frac{\partial f_{l+1,m}}{\partial x_{l,i}}$$

error signal
at layer 1

error signal
at layer 1

όπου $0 \leq l \leq L - 1$. Δηλαδή το σήμα σφάλματος ενός εσωτερικού κόμβου στο στρώμα l μπορεί να εκφραστεί ως γραμμικός συνδυασμός των κόμβων στο στρώμα $l + 1$. Επομένως, για οποιοδήποτε l και i και $[και\ 1 \leq i \leq N(l)]$, μπορούν να βρεθούν τα:

$$e_{l,i} = \frac{\partial^+ E_p}{\partial x_{l,i}}$$

εφαρμόζοντας πρώτα την πρώτη εξίσωση μία φορά για να υπολογιστούν τα σήματα σφάλματος στο επίπεδο εξόδου, και έπειτα εφαρμόζοντας την δεύτερη εξίσωση επαναληπτικά έως ότου καταλήξει η διαδικασία στο επιθυμητό επίπεδο l . Η διαδικασία αυτή καλείται οπισθοδρόμηση δεδομένου ότι τα σήματα σφάλματος λαμβάνονται διαδοχικά από το επίπεδο εξόδου προς το επίπεδο εισόδου.

Το διάνυσμα κλίσης ορίζεται ως την παράγωγο του μέτρου σφάλματος ως προς κάθε παράμετρο, έτσι πρέπει να εφαρμοστεί ο κανόνας αλυσίδας ξανά για να βρεθεί το διάνυσμα κλίσης. Εάν a είναι μια παράμετρος του i -οστού κόμβου στο επίπεδο l , τότε ισχύει:

$$\frac{\partial^+ E_p}{\partial a} = \frac{\partial^+ E_p}{\partial x_{l,i}} * \frac{\partial f_{l,i}}{\partial a} = e_{l,i} \frac{\partial f_{l,i}}{\partial a}$$

Ας σημειωθεί ότι αν επιτραπεί στην παράμετρο a να μοιράζεται μεταξύ διαφορετικών κόμβων, τότε η παραπάνω εξίσωση πρέπει να αλλαχθεί σε μια πιο γενική μορφή:

$$\frac{\partial^+ E_p}{\partial a} = \sum_{x^* \in S} \frac{\partial^+ E_p}{\partial x^*} * \frac{\partial f^*}{\partial a}$$

όπου S είναι το σύνολο των κόμβων που περιέχουν το a σαν παράμετρο ενώ x^* και f^* είναι η έξοδος και η συνάρτηση, αντίστοιχα, ενός γενικού κόμβου στο S .

Η παράγωγος του γενικού μέτρου σφάλματος E ως προς το a είναι:

$$\frac{\partial^+ E_p}{\partial a} = \sum_{p=1}^p \frac{\partial^+ E_p}{\partial a}$$

Συνεπώς, για την απλούστερη βαθμωτή ελαχιστοποίηση χωρίς ελαχιστοποίηση γραμμών, ο τύπος για τη γενική παράμετρο a είναι:

$$\Delta a = -\eta \frac{\partial^+ E_p}{\partial a}$$

όπου το η ο ρυθμός εκμάθησης, το οποίο μπορεί να εκφραστεί περαιτέρω ως:

$$\eta = \frac{k}{\sqrt{\sum a \left(\frac{\partial E}{\partial a}\right)^2}}$$


όπου το k είναι το μέγεθος βήματος, το μήκος δηλαδή κάθε μετάβασης κατά μήκος της κατεύθυνσης κλίσης στο διάστημα παραμέτρου. Συνήθως το μέγεθος βήματος μπορεί να αλλαχθεί για να μεταβληθεί η ταχύτητα της σύγκλισης.

Όταν ένα πρωσοτροφοδοτούμενο δίκτυο n -κόμβων αναπαριστάται στην τοπολογική του διάταξη, μπορεί να υπολογιστεί το μέτρο σφάλματος E_p σαν την έξοδο ενός επιπλέον κόμβου με ένδειξη $n + 1$, του οποίου η συνάρτηση κόμβου f_{n+1} μπορεί να οριστεί από τις εξόδους κάθε κόμβου με μικρότερη ένδειξη. (Επομένως, το E_p μπορεί να εξαρτάται άμεσα από οποιουσδήποτε κόμβους.) Εφαρμόζοντας πάλι τον κανόνα αλυσίδας, ισχύει ο ακόλουθος συνοπτικός τύπος για τον υπολογισμό του σήματος σφάλματος $\epsilon_i = \frac{\partial E_p}{\partial x_i}$:

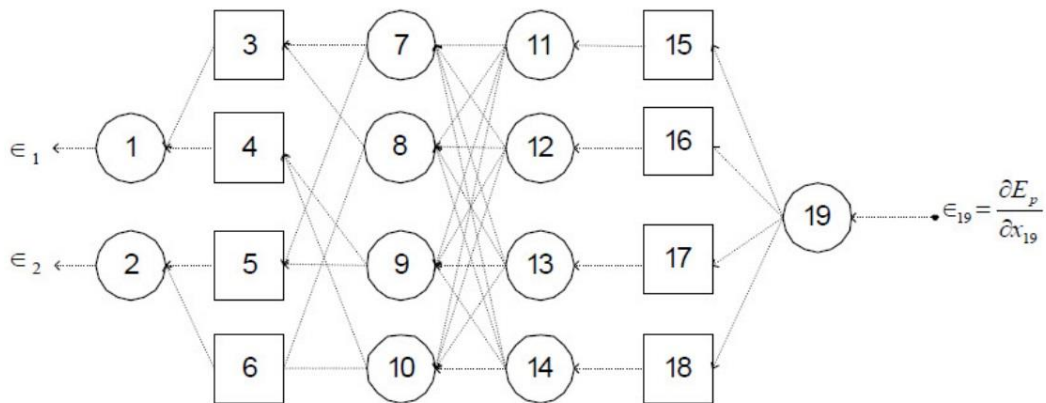
$$\epsilon_i = \frac{\partial f_{n+1}}{\partial x_i} + \sum_{j > i} \epsilon_j \frac{\partial f_j}{\partial x_i}$$

όπου ο πρώτος όρος δείχνει μια άμεση επίδραση του x_i στο E_p μέσω της άμεσης διαδρομής από τον κόμβο i στον κόμβο $n + 1$ και κάθε όρος παραγώγου στο άθροισμα δείχνει την έμμεση επίδραση του x_i στο E_p . Μόλις βρεθεί το σήμα σφάλματος για κάθε κόμβο, τότε το διάνυσμα κλίσης για τις παραμέτρους παράγεται όπως πριν.

Ένας άλλος συστηματικός τρόπος να υπολογιστούν τα σήματα σφάλματος είναι μέσω της αναπαράστασης του δικτύου διάδοσης σφάλματος (ή του μοντέλου ευαισθησίας), το οποίο λαμβάνεται από το αρχικό προσαρμοσμένο δίκτυο με την αντιστροφή των συνδέσεων και την παροχή των σημάτων σφάλματος στο επίπεδο εξόδου ως είσοδοι στο νέο δίκτυο. Τα ακόλουθα Σχήματα 4.7 και 4.8 δείχνουν το μοντέλο ANFIS και το δίκτυο διάδοσης σφάλματος του.



Σχήμα 4.7 Το Προσαρμοστικό Δίκτυο



Σχήμα 4.8 Το Δίκτυο Διάδοσης Σφάλματος

Τώρα θα υπολογιστούν τα σήματα στους εσωτερικούς κόμβους. Χρησιμοποιούνται τα f_i και x_i για το συμβολισμό της συνάρτησης και της εξόδου του κόμβου i . Η έξοδος του κόμβου i είναι το σήμα σφάλματος αυτού του κόμβου στο πραγματικό προσαρμοσμένο δίκτυο. Σε σύμβολα, αν επιλεγθεί το τετραγωνικό μέτρο σφάλματος για E_p , τότε ισχύει το ακόλουθο:

$$\epsilon_{19} = -2(d_{19} - x_{19})$$

Αυτό είναι επειδή ο κόμβος 19 είναι μόνο ένας κόμβος προσωρινής αποθήκευσης στο δίκτυο διάδοσης σφάλματος. Για τους κόμβους 15, 16, 17 και 18 ισχύουν:

$$\epsilon_{18} = \epsilon_{19} \frac{\partial f_{19}}{\partial x_{18}}$$

$$\epsilon_{17} = \epsilon_{19} \frac{\partial f_{19}}{\partial x_{17}}$$

$$\epsilon_{16} = \epsilon_{19} \frac{\partial f_{19}}{\partial x_{16}}$$

$$\epsilon_{15} = \epsilon_{19} \frac{\partial f_{19}}{\partial x_{15}}$$

Αυτό είναι επειδή όλοι αυτοί οι κόμβοι εξαρτώνται από τον κόμβο 19. Αυτό ισχύει και για τους κόμβους 11, 12, 13 και 14 με τη διαφορά ότι κάθε ένας από αυτούς εξαρτάται από διαφορετικό κόμβο:

$$\epsilon_{14} = \epsilon_{18} \frac{\partial f_{18}}{\partial x_{14}}$$

$$\epsilon_{13} = \epsilon_{17} \frac{\partial f_{17}}{\partial x_{13}}$$

$$\epsilon_{12} = \epsilon_{16} \frac{\partial f_{16}}{\partial x_{12}}$$

$$\epsilon_{11} = \epsilon_{15} \frac{\partial f_{15}}{\partial x_{11}}$$

Αντιθέτως, οι κόμβοι 7, 8, 9 και 10 εξαρτώνται από τέσσερις διαφορετικούς κόμβους όπως φαίνεται στο Σχήμα 5.8. Έτσι, ισχύει:

$$\epsilon_{10} = \epsilon_{14} \frac{\partial f_{14}}{\partial x_{10}} + \epsilon_{13} \frac{\partial f_{13}}{\partial x_{10}} + \epsilon_{12} \frac{\partial f_{12}}{\partial x_{10}} + \epsilon_{11} \frac{\partial f_{11}}{\partial x_{10}}$$

$$\epsilon_9 = \epsilon_{14} \frac{\partial f_{14}}{\partial x_9} + \epsilon_{13} \frac{\partial f_{13}}{\partial x_9} + \epsilon_{12} \frac{\partial f_{12}}{\partial x_9} + \epsilon_{11} \frac{\partial f_{11}}{\partial x_9}$$

$$\epsilon_8 = \epsilon_{14} \frac{\partial f_{14}}{\partial x_8} + \epsilon_{13} \frac{\partial f_{13}}{\partial x_8} + \epsilon_{12} \frac{\partial f_{12}}{\partial x_8} + \epsilon_{11} \frac{\partial f_{11}}{\partial x_8}$$

$$\epsilon_7 = \epsilon_{14} \frac{\partial f_{14}}{\partial x_7} + \epsilon_{13} \frac{\partial f_{13}}{\partial x_7} + \epsilon_{12} \frac{\partial f_{12}}{\partial x_7} + \epsilon_{11} \frac{\partial f_{11}}{\partial x_7}$$

Οι κόμβοι 3, 4, 5 και 6 εξαρτώνται από δύο διαφορετικούς κόμβους και σαν αποτέλεσμα προκύπτουν οι ακόλουθες σχέσεις:

$$\epsilon_6 = \epsilon_{10} \frac{\partial f_{10}}{\partial x_6} + \epsilon_8 \frac{\partial f_8}{\partial x_6}$$

$$\epsilon_5 = \epsilon_9 \frac{\partial f_9}{\partial x_5} + \epsilon_7 \frac{\partial f_7}{\partial x_5}$$

$$\epsilon_4 = \epsilon_{10} \frac{\partial f_{10}}{\partial x_4} + \epsilon_9 \frac{\partial f_9}{\partial x_4}$$

$$\epsilon_3 = \epsilon_8 \frac{\partial f_8}{\partial x_3} + \epsilon_7 \frac{\partial f_7}{\partial x_3}$$

Τέλος, οι κόμβοι 1 και 2 εξαρτώνται από δύο κόμβους και έτσι ισχύει:

$$\begin{aligned}\epsilon_2 &= \epsilon_6 \frac{\partial f_2}{\partial x_2} + \epsilon_5 \frac{\partial f_5}{\partial x_2} \\ \epsilon_1 &= \epsilon_4 \frac{\partial f_4}{\partial x_1} + \epsilon_3 \frac{\partial f_3}{\partial x_1}\end{aligned}$$

4.9 Συνδυασμός Βαθμωτής Ελαχιστοποίησης & Εκτιμητή Ελαχίστων Τετραγώνων

Η έξοδος ενός προσαρμόσιμου δικτύου είναι γραμμική σε μερικές από τις παραμέτρους του δικτύου. Έτσι μπορούν να προσδιοριστούν αυτές οι γραμμικές παράμετροι με τη γραμμική μέθοδο ελαχίστων τετραγώνων που περιγράφηκε παραπάνω. Αυτή η προσέγγιση οδηγεί σε ένα υβριδικό κανόνα εκμάθησης που συνδυάζει τη βαθμωτή ελαχιστοποίηση (SD) και τον εκτιμητή ελαχίστων τετραγώνων (LSE) για γρήγορο προσδιορισμό των παραμέτρων.

Παρατηρώντας το δίκτυο ANFIS, που μόλις περιγράφηκε, προκύπτει το συμπέρασμα ότι δοθέντων των τιμών των παραμέτρων του «εάν» τμήματος του κανόνα, το συνολικό αποτέλεσμα μπορεί να εκφραστεί ως ένας γραμμικός συνδυασμός των παραμέτρων του «τότε» τμήματος του κανόνα. Συγκεκριμένα το αποτέλεσμα f μπορεί να ξαναγραφεί ως:

$$f = \overline{w}_1 f_1 + \overline{w}_2 f_2 = (\overline{w}_1 x_1) p_1 + (\overline{w}_1 x_2) q_1 + (\overline{w}_1) r_1 + (\overline{w}_2 x_1) p_2 + (\overline{w}_2 x_2) q_2 + (\overline{w}_2) r_2$$

Η σχέση αυτή είναι γραμμική ως προς τις παραμέτρους $(p_1, q_1, r_1, p_2, q_2, r_2)$. Οπότε, ένας αλγόριθμος μάθησης που θα περιλαμβάνει μη γραμμικές τεχνικές, όπως η βαθμωτή κατάβαση (gradient descend), αλλά και γραμμικές, όπως η μέθοδος ελαχίστων τετραγώνων, μπορεί να χρησιμοποιηθεί.

Με βάση την παρατήρηση αυτή έχουμε στην εξίσωση:

$$S = S_1 \oplus S_2$$

S = σύνολο των συνολικών παραμέτρων

S_1 = σύνολο των (μη γραμμικών) παραμέτρων του τμήματος «υπόθεση» (premise) των κανόνων

S_2 = σύνολο των (γραμμικών) παραμέτρων του τμήματος «απόδοση» (consequent) των κανόνων.

Η $H(\cdot)$ είναι η ταυτοτική συνάρτηση και η $F(\cdot, \cdot)$ είναι η συνάρτηση του συστήματος ασαφούς συμπερασμού αντίστοιχα. Κατά συνέπεια, ο υβριδικός αλγόριθμος μάθησης που αναπτύχθηκε παραπάνω μπορεί να εφαρμοστεί

άμεσα. Αναλυτικότερα, όπως συμβαίνει και στα νευρωνικά δίκτυα, θα ξεχωρίσουν δύο φάσεις στη διαδικασία εκπαίδευσης:

- A. **Πέρασμα προς τα εμπρός (forward pass):** Στη φάση αυτή το σήμα εισόδου διαδίδεται από το επίπεδο 1 μέχρι το επίπεδο 4 και οι παράμετροι $(p_i, q_i, r_i)_{i=1,2}$ εκτιμούνται με τη μέθοδο των ελαχίστων τετραγώνων.
- B. **Πέρασμα προς τα πίσω (backward pass):** Στη φάση αυτή έχοντας μία ένδειξη του λάθους πραγματοποιείται μία διόρθωση κατά μία ποσότητα που ορίζεται από τη μέθοδο της βαθμωτής κατάβασης (Gradient Descent), των μεταβλητών a_i, b_i, c_i .

Το ANFIS διασπά το σύνολο των παραμέτρων του σε δύο υποσύνολα, εκ των οποίων το ένα αποτελεί γραμμικό σύνολο παραμέτρων και, επομένως, είναι δυνατόν να εκπαιδευτεί με γραμμικούς αλγόριθμους, όπως η μέθοδος των ελαχίστων τετραγώνων (least squared). Οι γραμμικοί αλγόριθμοι μάθησης επιτυγχάνουν συνολικά ελάχιστα (global minimums) της συνάρτησης κόστους στο χώρο των παραμέτρων τους και είναι αποδοτικοί από πλευράς απαιτούμενου υπολογιστικού χρόνου. Το δεύτερο υποσύνολο παραμέτρων εκπαιδεύεται με αλγόριθμους που μπορούν να δημιουργήσουν μη-γραμμικές απεικονίσεις, όπως η βαθμωτή κατάβαση (gradient descent). Οι αλγόριθμοι αυτοί είναι απαιτητικοί από πλευράς απαιτούμενου χρόνου εκπαίδευσης και δεν υπάρχει εγγύηση για την πραγματοποίηση του συνολικού ελαχίστου της συνάρτησης κόστους στον χώρο των παραμέτρων τους. Ο αλγόριθμος μάθησης του ANFIS συνδυάζει περάσματα προς τα εμπρός και προς τα πίσω. Στο πέρασμα εμπρός γίνεται η μάθηση του συνόλου των γραμμικών παραμέτρων και στο πέρασμα προς τα πίσω γίνεται η προσαρμογή των μη – γραμμικών αντίστοιχα. Στον παρακάτω Πίνακα 5.1 συνοψίζονται οι δραστηριότητες του κάθε περάματος.

Πίνακας 4.1 Δραστηριότητες κατά την Εκπαίδευση

	Εμπροσθόδρομο Πέρασμα	Οπισθόδρομο Πέρασμα
Παράμετροι Προϋποθέσεων	Προκαθορισμένες (Αμετάβλητες)	Βαθμωτή Φθίνουσα Μέθοδος
Παράμετροι Συμπερασμάτων	Εκτιμήτρια Ελαχίστων Τετραγώνων	Προκαθορισμένες (Αμετάβλητες)
Σήματα	Έξοδοι των Κόμβων	Σήματα Σφάλματος

Το πλεονέκτημα της μεθόδου έγκειται στο γεγονός της ύπαρξης τόσο γραμμικών όσο και μη γραμμικών μεθόδων, που την καθιστά ταχύτερη από τα κλασικά νευρωνικά δίκτυα. Όπως αναφέρθηκε και παραπάνω, το ANFIS εμφανίζει μεγάλη ομοιότητα με το δίκτυο RBF, που χρησιμοποιεί τον ίδιο περίπου υβριδικό αλγόριθμο εκπαίδευσης [27].

Μέχρι τώρα χρησιμοποιούσαμε προκαθορισμένες και αυθαίρετα επιλεγμένες συναρτήσεις συμμετοχής. Πολλές φορές έχουμε μια συλλογή από δεδομένα εισόδου/εξόδου και δεν μπορούμε να χρησιμοποιήσουμε ένα προκαθορισμένο μοντέλο βασισμένο στα στοιχεία αυτά ώστε να ξέρουμε ποιες συναρτήσεις συμμετοχής και με ποιες παραμέτρους να χρησιμοποιήσουμε. Τότε μπορούμε να βοηθηθούμε από το ANFIS, ώστε να βρούμε τις καταλληλότερες συναρτήσεις συμμετοχής.

Οι νεύρο-προσαρμοστικές τεχνικές είναι αρκετά απλές. Έτσι παρέχεται μια μέθοδος ώστε το ασαφές μοντέλο να εκπαιδευτεί με τις πληροφορίες που του δίνει το σύνολο των δεδομένων, ώστε να υπολογιστούν οι παράμετροι των συναρτήσεων συμμετοχής με σκοπό την εύρεση του καλύτερου τρόπου ώστε να επιτρέπει στο σύστημα εξαγωγής συμπερασμάτων να ανιχνεύει τα δεδομένα εισόδου/ εξόδου. Η μέθοδος αυτή είναι παρόμοια με αυτή των νευρωνικών δικτύων.

Η προσαρμογή των παραμέτρων των συναρτήσεων συμμετοχής από ένα ANFIS γίνεται με αλγόριθμους εκμάθησης είτε μόνο back – propagation είτε με έναν υβριδικό αλγόριθμο, συνδυασμό back – propagation και μεθόδου ελαχίστων τετραγώνων.

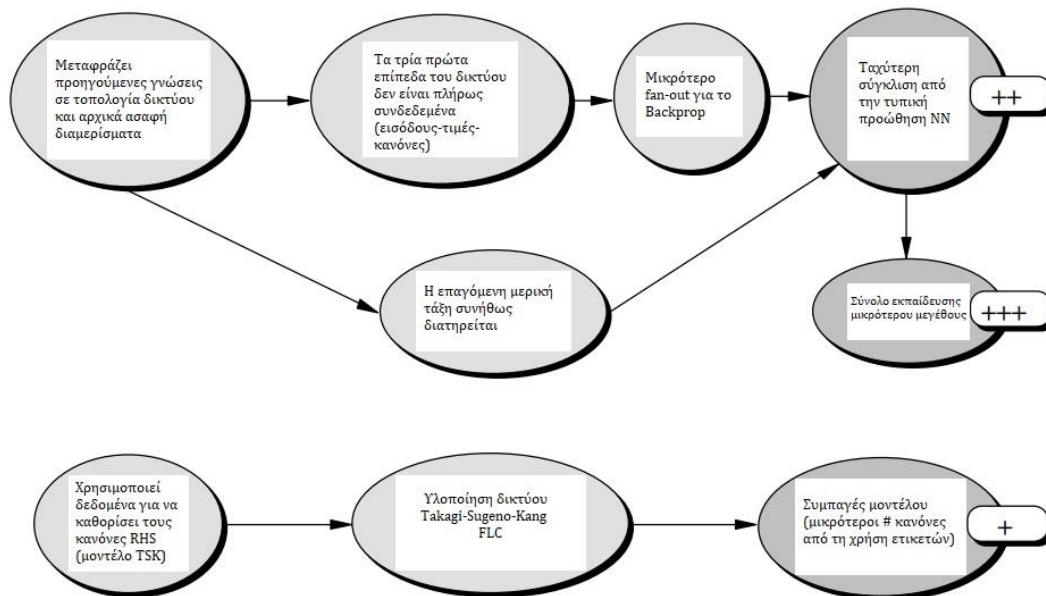
Ο υπολογισμός των παραμέτρων αυτών, που αλλάζουν κατά τη διάρκεια της διαδικασίας εκμάθησης, διευκολύνεται από ένα βαθμωτό διάνυσμα που μας δείχνει πόσο καλά το FIS μοντελοποιεί τα δεδομένα εισόδου/ εξόδου για το εν λόγω σύνολο παραμέτρων. Μόλις αποκτήσουμε το βαθμωτό διάνυσμα μπορούμε να εφαρμόσουμε κάποιον από τους πολλούς αλγόριθμους βελτιστοποίησης, για να βελτιώσουμε αυτές τις παραμέτρους, ούτως ώστε να μειώσουμε το μέγεθος του σφάλματος (συνήθως το άθροισμα των τετραγώνων των διαφορών μεταξύ πραγματικών και επιθυμητών τιμών) [28].

4.10 Πλεονεκτήματα, Μειονεκτήματα και Περιορισμοί του ANFIS

ΠΛΕΟΝΕΚΤΗΜΑΤΑ ANFIS

Χαρακτηριστικά

Πλεονεκτήματα

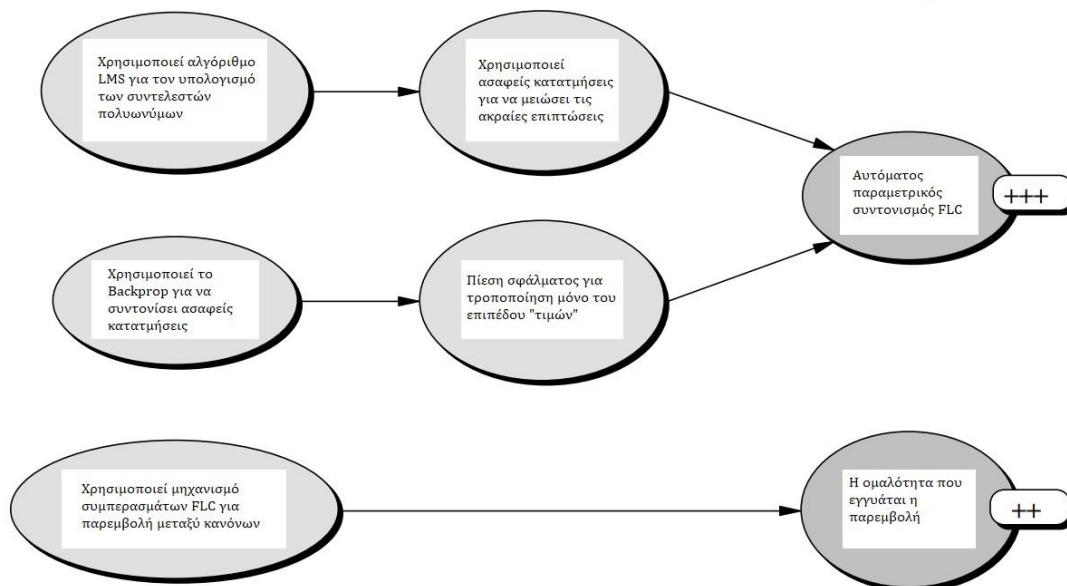


(a)

ΠΛΕΟΝΕΚΤΗΜΑΤΑ ANFIS

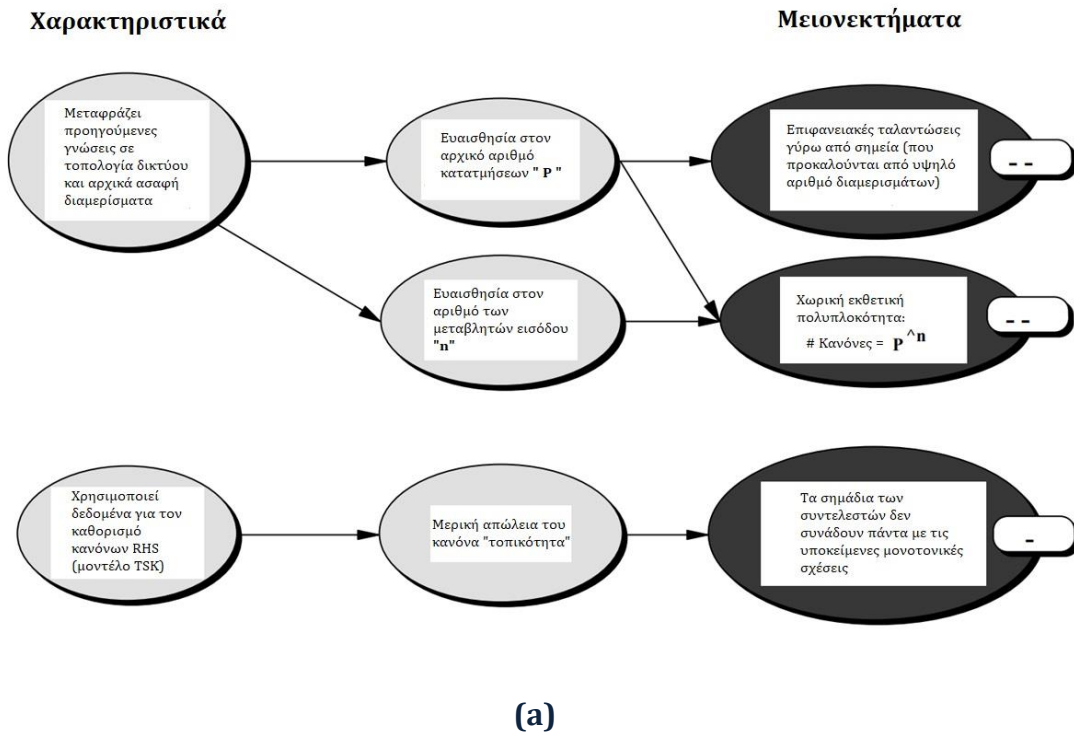
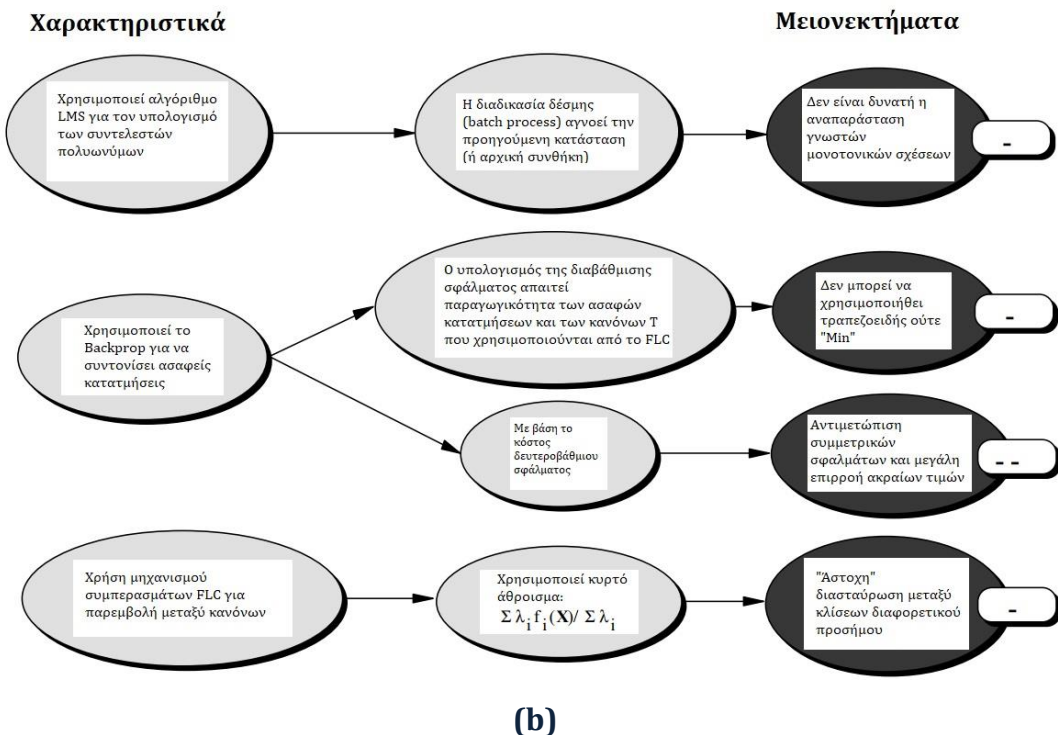
Χαρακτηριστικά

Πλεονεκτήματα



(b)

Διάγραμμα 4.2 Πλεονεκτήματα ANFIS (a), (b)

ΜΕΙΟΝΕΚΤΗΜΑΤΑ ANFIS**ΜΕΙΟΝΕΚΤΗΜΑΤΑ ANFIS**

Διάγραμμα 4.3 Μειονεκτήματα ANFIS (a), (b)

Η μέθοδος ANFIS πράγματι συνδυάζει τα πλεονεκτήματα των νευρωνικών δικτύων και της ασαφούς λογικής, παρέχοντας **ομαλότητα**, λόγω της παρεμβολής ασαφούς ελέγχου και **προσαρμοστικότητα**, που προέρχεται από

τα νευρωνικά δίκτυα μέσω της αλγόριθμου οπισθοδρόμησης. Ωστόσο, η ANFIS έχει ισχυρούς περιορισμούς υπολογιστικής πολυπλοκότητας [26].

Περιορισμοί

Οι κυριότεροι περιορισμοί του ANFIS που αναφέρονται στην διεθνή βιβλιογραφία είναι:

- Βασίζεται σε ένα FIS τύπου Sugeno.
- Έχει μια έξοδο, που λαμβάνεται με τη μέθοδο αποσαφήνισης σταθμισμένου μέσου. Όλες οι συναρτήσεις συμμετοχής εξόδου πρέπει να είναι ίδιου τύπου, είτε γραμμικές είτε σταθερές.
- Δεν μπορεί να γίνεται κοινή χρήση κανόνων. Διαφορετικοί κανόνες δεν μπορούν να έχουν την ίδια συνάρτηση συμμετοχής εξόδου.
- Πρέπει να υπάρχουν βάρη σε κάθε κανόνα.
- Δεν μπορεί να χρησιμοποιηθεί οποιαδήποτε συνάρτηση συμμετοχής, παρά μόνο προκαθορισμένες που επιβάλλουν οι ορισμοί του ANFIS [28].

5^ο ΚΕΦΑΛΑΙΟ



ΑΠΟΤΕΛΕΣΜΑΤΑ
ANFIS

ΚΕΦΑΛΑΙΟ 5ο – ΑΠΟΤΕΛΕΣΜΑΤΑ ANFIS

5.1 Αποτελέσματα από την χρήση του μοντέλου ANFIS

5.1.1 Βάση Δεδομένων

Τα δεδομένα για το μοντέλο ANFIS είναι πιστοποιημένες μετρήσεις για 365 μέρες από 09/03/2005 μέχρι 22/03/2006, από τέσσερις ανεμογεννήτριες από αιολικό πάρκο σε νησί της Ελλάδας. Οι τιμές των μεταβλητών καταγράφηκαν σε τέσσερα αρχεία Excel, αναλυτικά με ημερομηνία και χρονολογία σε κάθε γραμμή. Οι καταγεγραμμένες μεταβλητές είναι οι εξής:

- Ελάχιστη ταχύτητα ανέμου (m/s)
- Μέση ταχύτητα ανέμου (m/s)
- Μεγίστη τιμή ανέμου (m/s)
- Ελάχιστη ταχύτητα περιστροφής του ρότορα (rpm)
- Μέση ταχύτητα περιστροφής του ρότορα (rpm)
- Μεγίστη ταχύτητα περιστροφής ρότορα (rpm)
- Ελάχιστη αποδιδόμενη ισχύς (kw)
- Μέση αποδιδόμενη ισχύς (kw)
- Μεγίστη αποδιδόμενη ισχύς (kw)
- Ώρες λειτουργίας (h)
- Παραχθείσα ενεργεία (kwh)

5.1.2 Περιγραφή Μοντέλων Πρόβλεψης

Σε αυτό το κομμάτι της εργασίας δημιουργήθηκε ο κώδικας σε γλωσσά προγραμματισμού Matlab με τη βοήθεια του Fuzzy Logic Toolbox, το οποίο περιέχει όλα τα απαραίτητα εργαλεία για την ανάπτυξη και χρήση ενός προσαρμοστικού νευροσαφούς συστήματος συμπερασμού (ANFIS), για την πραγματοποίηση της πρόβλεψης της παραγωγής ηλεκτρικής ενέργειας από ανεμογεννήτριες. Στη περίπτωση μας επιχειρείται η πρόβλεψη παραγωγής ενέργειας της επόμενης μέρας (one step ahead) στις τέσσερις ανεμογεννήτριες.

Στο παρόν ερευνητικό έργο αναπτύχθηκαν δυο μοντέλα ANFIS. Το πρώτο αποτελείται από δυο εισόδους οι οποίες είναι η μέση ταχύτητα

αέρα (m/s) και η μέση αποδιδόμενη ισχύς (Kw), ενώ έξοδος είναι η παραχθείσα ηλεκτρική ενέργεια της επόμενης μέρας (kwh). Το δεύτερο αποτελείται από τρεις εισόδους οι οποίες είναι η μέση ταχύτητα αέρα (m/s), η μέση ταχύτητα περιστροφής του ρότορα (rpm) και η μέση αποδιδόμενη ισχύς (kw), ενώ έξοδος είναι και πάλι η παραχθείσα ηλεκτρική ενέργεια της επόμενης μέρας (kwh). Στον πιο κάτω Πίνακα 5.1 παρουσιάζονται τα μοντέλα.

Πίνακας 5.1 Μοντέλα ANFIS

ANFIS 2-1	2-είσοδοι δεδομένα Ανεμογεννήτριας 1
ANFIS 2-2	2-είσοδοι δεδομένα Ανεμογεννήτριας 2
ANFIS 2-3	2-είσοδοι δεδομένα Ανεμογεννήτριας 3
ANFIS 2-4	2-είσοδοι δεδομένα Ανεμογεννήτριας 4
ANFIS 3-1	3-είσοδοι δεδομένα Ανεμογεννήτριας 1
ANFIS 3-2	3-είσοδοι δεδομένα Ανεμογεννήτριας 2
ANFIS 3-3	3-είσοδοι δεδομένα Ανεμογεννήτριας 3
ANFIS 3-4	3-είσοδοι δεδομένα Ανεμογεννήτριας 4

Από το σύνολο των 365 διαφορετικών τιμών των μεταβλητών το 88% χρησιμοποιήθηκε για την εκπαίδευση των μοντέλων και το 12% για την αξιολόγηση της πρόβλεψης και για τις οκτώ περιπτώσεις. Επίσης σημαντικό είναι να αναφερθεί ότι στα μοντέλα ANFIS, ο αριθμός των παραμέτρων των συναρτήσεων συμμετοχής, δεν μπορεί να ξεπερνά το ένα τέταρτο του αριθμού των δεδομένων εκπαίδευσης για να αποφύγουμε τη περίπτωση της υπερπροσαρμογής καθώς και για να μην χάσουμε την δυνατότητα γενίκευσης [29].

5.1.3 Επιλογή Συναρτήσεων Συμμετοχής (Membership Function/MF)

Το πιο σημαντικό βήμα σε ένα μοντέλο ANFIS είναι ο καθορισμός της κατάλληλης συνάρτησης συμμετοχής και των αντίστοιχων τιμών της. Στη περίπτωση των μοντέλων μας, χρησιμοποιήσαμε δυο συναρτήσεις συμμετοχής για κάθε είσοδο και για τα δυο μοντέλα ANFIS 2 και ANFIS 3.

Για την επιλογή της κατάλληλης συνάρτησης συμμετοχής για κάθε περίπτωση πραγματοποιήθηκαν δοκιμές με τις συναρτήσεις:


- Γενικευμένη καμπανοειδής συνάρτηση συμμετοχής (Gbellmf)
- Τριγωνοειδής συνάρτηση συμμετοχής (trimf)
- Δυο γκαουσιανές συναρτήσεις συμμετοχής (Gauss2mf)
- Γκαουσιανή συνάρτηση συμμετοχής (Gaussmf)
- Τραπεζοειδής συνάρτηση συμμετοχής (Trapmf)

Επίσης έγιναν δοκιμές με διαφορετικό αριθμό εποχών (epochs) μέχρι να βρεθεί ο κατάλληλος αριθμός για κάθε περίπτωση. Μετά από πολλές δοκιμές επιλέχθηκαν τα ακόλουθα.


- ANFIS 2-1: Τραπεζοειδής συνάρτηση συμμετοχής (Trapmf) στις **300** εποχές (epochs)
- ANFIS 2-2: Γκαουσιανή συνάρτηση συμμετοχής (Gaussmf) στις **2000** εποχές(epochs)
- ANFIS 2-3 : Γκαουσιανή συνάρτηση συμμετοχής (Gaussmf) στις **400** εποχές (epochs)
- ANFIS 2-4: Τριγωνοειδής συνάρτηση συμμετοχής (Trimf) στις **100** εποχές (epochs)
- ANFIS 3-1: Τριγωνοειδής συνάρτηση συμμετοχής (Trimf) στις **300** εποχές (epochs)
- ANFIS 3-2: Τριγωνοειδής συνάρτηση συμμετοχής (Trimf) στις **300** εποχές (epochs)
- ANFIS 3-3: Τριγωνοειδής συνάρτηση συμμετοχής (Trimf) στις **300** εποχές (epochs)
- ANFIS 3-4: Τριγωνοειδής συνάρτηση συμμετοχής (Trimf) στις **250** εποχές (epochs)

5.1.4 Στάδιο Εκπαίδευσης

Μετά των καθορισμών των συναρτήσεων συμμετοχής, ο υβριδικός αλγόριθμος του ANFIS που συνδυάζει τον αλγόριθμο οπισθόδρομης διάδοσης (back propagation algorithm) και την μέθοδο ελαχίστων τετραγώνων, προσαρμόζει τις παραμέτρους των συναρτήσεων συμμετοχής με βάση τα δεδομένα εκπαίδευσης. Τα παρακάτω σχήματα αποτελούνται από δυο γραφικές παραστάσεις. Στην πρώτη (Γράφημα 5.1) απεικονίζεται το σφάλμα εκπαίδευσης (training error) συναρτήσει του αριθμού επαναλήψεων (epochs). Στην δεύτερη γραφική παράσταση (Γράφημα 5.2) απεικονίζεται η καμπύλη του μεγέθους βήματος (step size) συναρτήσει των επαναλήψεων (epochs) για την κατάλληλη προσαρμογή του αρχικού μεγέθους βήματος. Για οικονομία χώρου, παρουσιάζονται τα διαγράμματα των ANFIS 2-4 και ANFIS 3-4 που στα αποτελέσματα που θα παρουσιαστούν πιο κάτω είχαν το χαμηλότερο σφάλμα πρόβλεψης.




Διάγραμμα 5.1 ANFIS 2-4 Matlab




Διάγραμμα 5.2 ANFIS 3-4 Matlab

Όπως φαίνεται οι εποχές που επιλέχθηκαν είναι αρκετές, διότι το ελάχιστο σφάλμα εκπαίδευσης λαμβάνει χώρα για αρκετές εποχές πριν σταματήσει η εκπαίδευση στις 100 και 250 εποχές αντίστοιχα.


Παρακάτω παρουσιάζονται τα Διαγράμματα των αρχικών (initial mf) και τελικών (final mf) συναρτήσεων συμμετοχής.




Διάγραμμα 5.3 ANFIS 2-4 Matlab - Αρχικές Συναρτήσεις Συμμετοχής



Διάγραμμα 5.4 ANFIS 3-4 Matlab - Αρχικές Συναρτήσεις Συμμετοχής



Διάγραμμα 5.5 ANFIS 2-4 Matlab – Τελικές Συναρτήσεις Συμμετοχής




Διάγραμμα 5.6 ANFIS 3-4 Matlab – Τελικές Συναρτήσεις Συμμετοχής

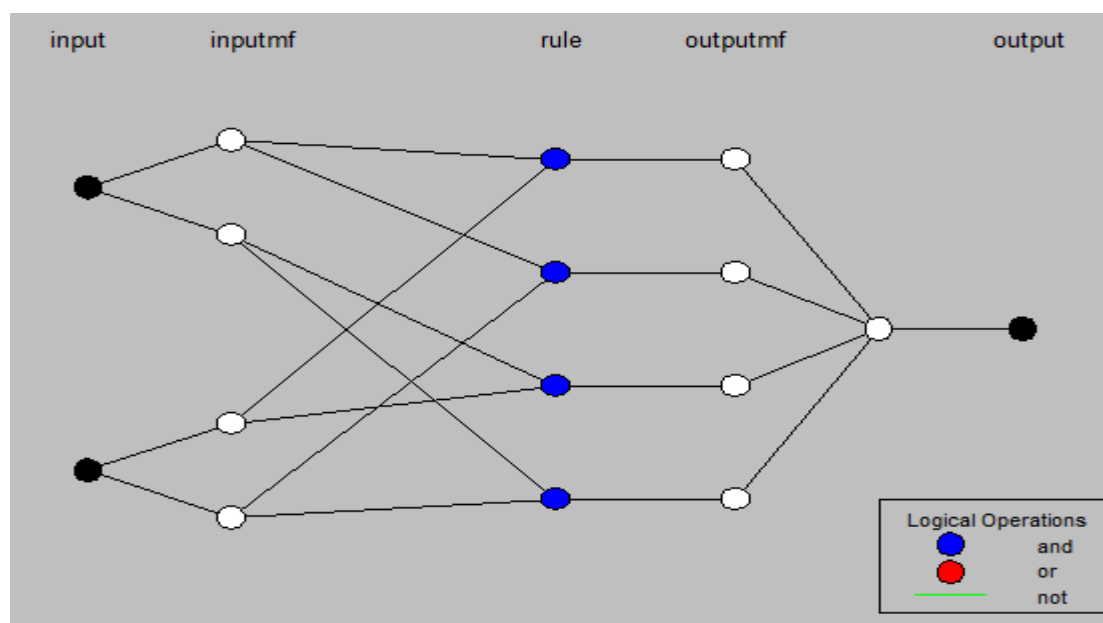
5.1.5 Κανόνες (Rules) και Δομή Μοντέλων ANFIS

Ο αριθμός των κανόνων καθορίζεται από τον αριθμό των εισερχόμενων μεταβλητών με τη μορφή 2^n , όπου 2 είναι ο αριθμός των συναρτήσεων συμμετοχής που ανατίθενται σε κάθε είσοδο και n είναι ο αριθμός των εισερχόμενων μεταβλητών.

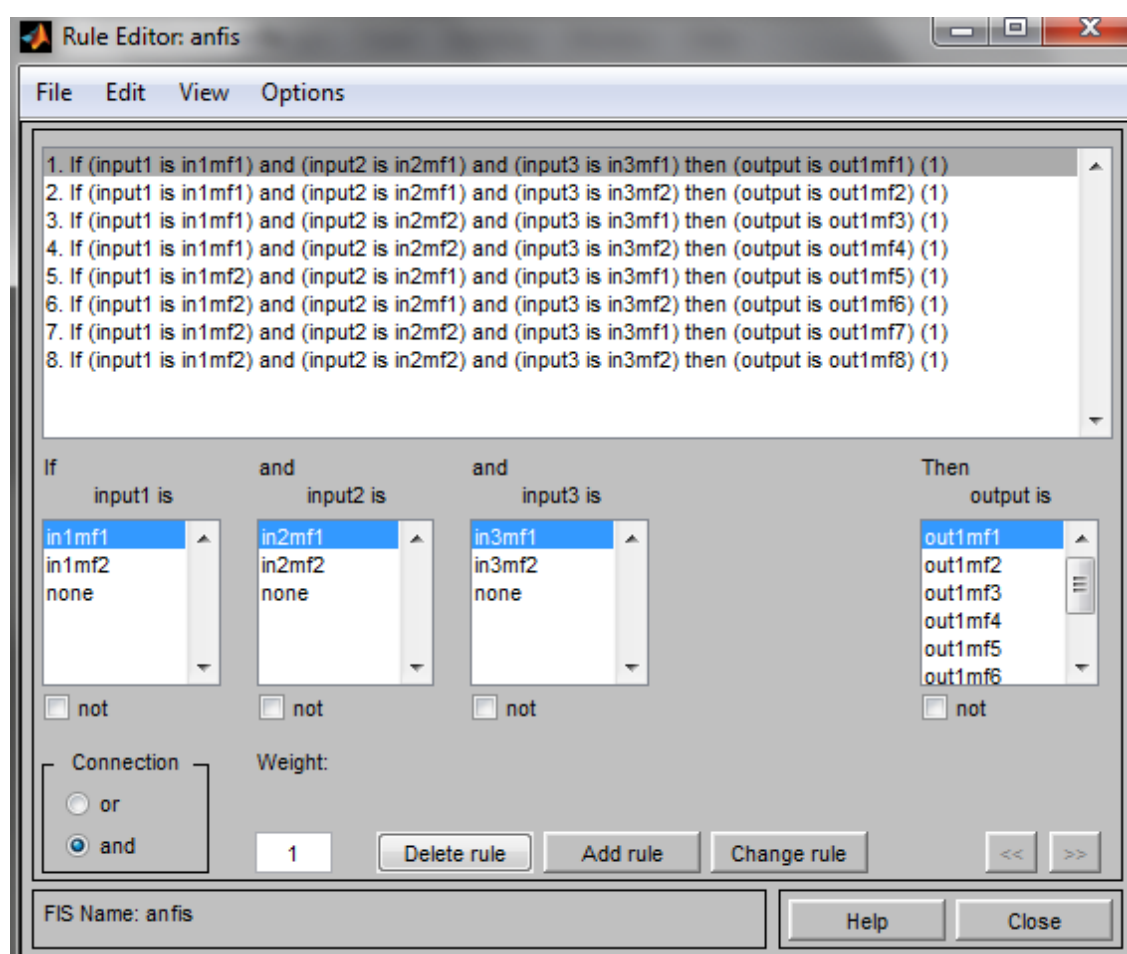
Στη περίπτωση μας έχουμε τέσσερις κανόνες για το μοντέλο ANFIS 2 (Εικόνα 5.1) και οκτώ κανόνες για το μοντέλο ANFIS 3 (Εικόνα 5.3). Πιο κάτω παρουσιάζονται η δομή των κανόνων για τις δυο περιπτώσεις και η αρχιτεκτονική των μοντέλων ANFIS (Εικόνες 5.2 και 5.4 αντίστοιχα).



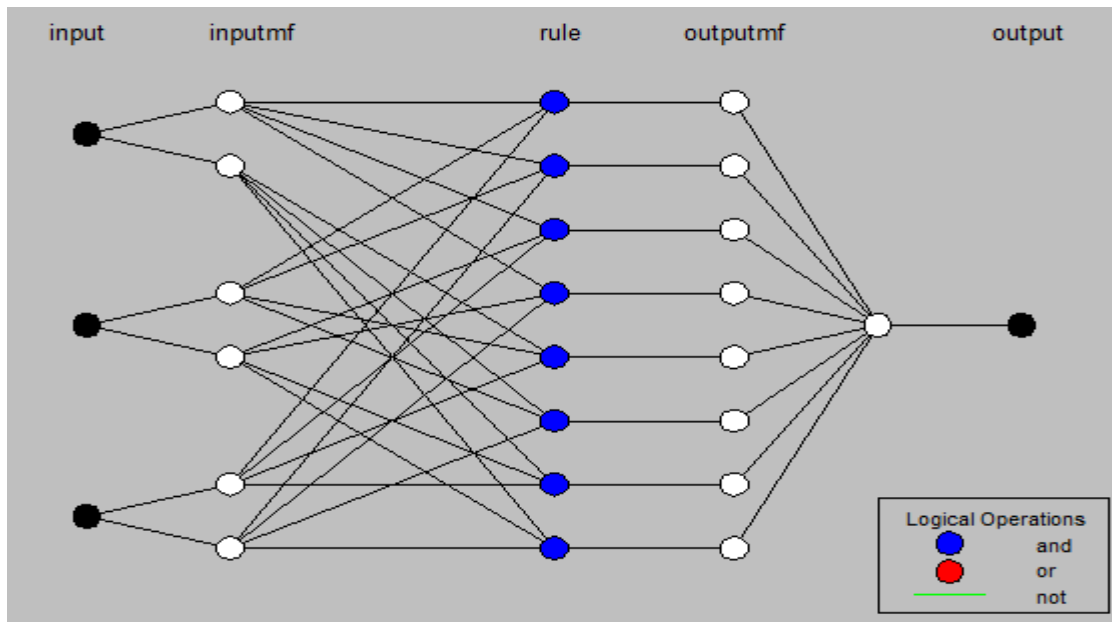
Εικόνα 5.1 ANFIS 2 Matlab – Δομή Τεσσάρων Κανόνων



Εικόνα 5.2 ANFIS 2 Matlab – Αρχιτεκτονική ANFIS 2




Εικόνα 5.3 ANFIS 3 Matlab – Δομή Οκτώ Κανόνων



Εικόνα 5.4 ANFIS 3 Matlab – Αρχιτεκτονική ANFIS 3

5.1.6 Δεδομένα Παραγωγής Ηλεκτρικής Ενέργειας από Ανεμογεννήτρια 4


Στο Διάγραμμα 5.7 που ακολουθεί, φαίνονται οι πραγματικές τιμές παραγωγής ηλεκτρικής ενέργειας (kwh) συναρτήσει των 365 ημερών.




Διάγραμμα 5.7 Πραγματικές Τιμές Παραγωγής Ηλεκτρικής Ενέργειας (kwh)/ 365 Ημέρες

5.1.7 Διαγράμματα Δεδομένων Εκπαίδευσης


Παρακάτω παρουσιάζονται τα Διαγράμματα δεδομένων εκπαίδευσης για τις εισόδους των δυο μοντέλων ANFIS 2-4 (Διάγραμμα 5.8) και ANFIS 3-4 (Διάγραμμα 5.11), καθώς και για την έξοδο που είναι η παράγωγη ηλεκτρικής ενέργειας της επόμενης μέρας συναρτήσει του χρόνου (ήμερες)(Διαγράμματα 5.9 και 5.12). Επίσης έχουμε τα διαγράμματα διασποράς των δεδομένων εισόδου (inputs) σε σχέση με την έξοδο (output) (Διαγράμματα 5.10 και 5.13).




Διάγραμμα 5.8 ANFIS 2-4 Δεδομένα Εκπαίδευσης – Είσοδοι




Διάγραμμα 5.9 ANFIS 2-4 Δεδομένα Εκπαίδευσης – Έξοδοι




Διάγραμμα 5.10 ANFIS 2-4 Διασπορά Εισόδου -Εξόδου



Διάγραμμα 5.11 ANFIS 3-4 Δεδομένα Εκπαίδευσης - Είσοδοι




Διάγραμμα 5.12 ANFIS 3-4 Δεδομένα Εκπαίδευσης - Έξοδοι




Διάγραμμα 5.13 ANFIS 3-4 Διασπορά Εισόδου - Εξόδου

5.1.8 Διαγράμματα Διασποράς Δεδομένων Αξιολόγησης

Στα Διαγράμματα 5.14 και 5.15 έχουμε τα δεδομένα αξιολόγησης (δεδομένα πρόβλεψης) διασποράς των εισόδων (inputs) συναρτήσει της εξόδου (output).



Διάγραμμα 5.14 ANFIS 2-4 Δεδομένα Πρόβλεψης Διασποράς εισόδων Συναρτήσεως της Εξόδου



Διάγραμμα 5.15 ANFIS 3-4 Δεδομένα Πρόβλεψης Διασποράς εισόδων Συναρτήσεως της Εξόδου

5.1.9 Χαρακτηριστικά Μοντέλων ANFIS

Στις Εικόνες 5.5 και 5.6 από την Matlab εμφανίζονται τα χαρακτηριστικά των δυο μοντέλων ANFIS 2 και ANFIS 3 που παρουσιάζονται στο παρόν ερευνητικό έργο.

abc	name	'anfis'
abc	type	'sugeno'
abc	andMethod	'prod'
abc	orMethod	'max'
abc	defuzzMethod	'wtaver'
abc	impMethod	'prod'
abc	aggMethod	'max'
E	input	<1x2 struct>
E	output	<1x1 struct>
E	rule	<1x4 struct>

Εικόνα 5.5 ANFIS 2

abc	name	'anfis'
abc	type	'sugeno'
abc	andMethod	'prod'
abc	orMethod	'max'
abc	defuzzMethod	'wtaver'
abc	impMethod	'prod'
abc	aggMethod	'max'
E	input	<1x3 struct>
E	output	<1x1 struct>
E	rule	<1x8 struct>

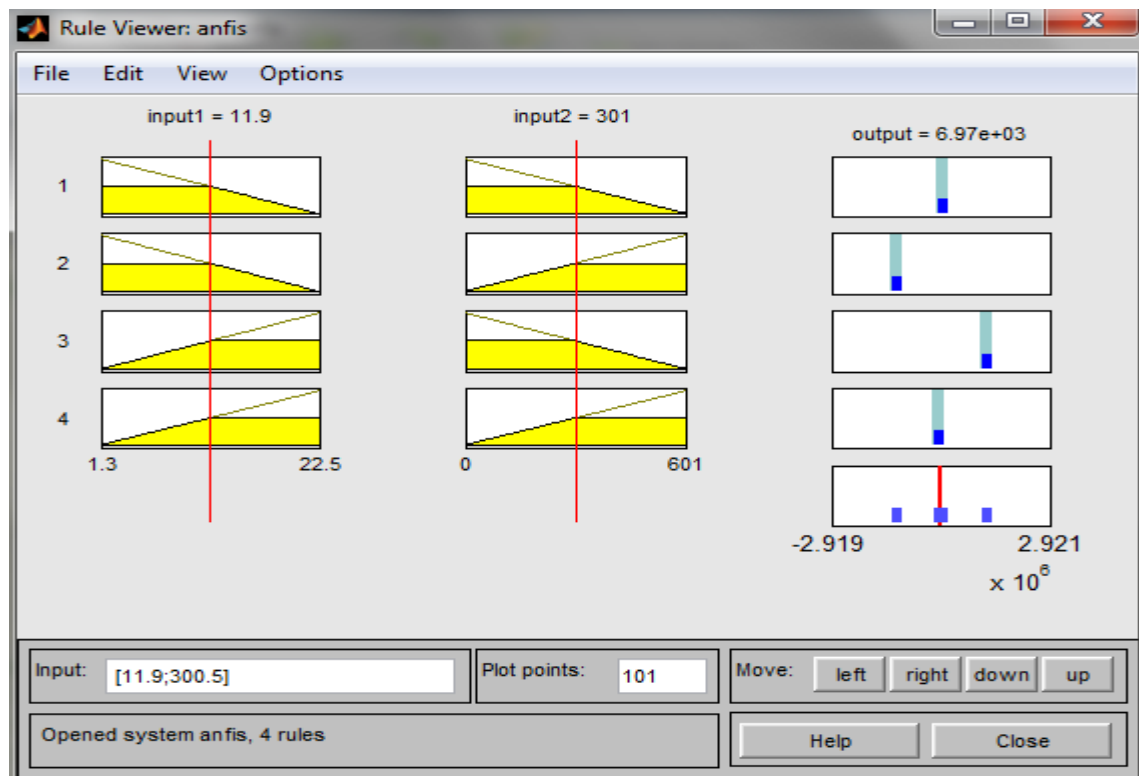
Εικόνα 5.6 ANFIS 3

Με βάση και την τελική επιλογή των συναρτήσεων συμμετοχής για τα δυο μοντέλα που παρουσιάζονται αναλυτικά σε αυτό το κεφάλαιο, έχουμε για το ANFIS 2 συνολικά 28 παραμέτρους (16 μη γραμμικές και 12 γραμμικές) και για το ANFIS 3 έχουμε 50 παραμέτρους (18 μη γραμμικές και 32 γραμμικές).

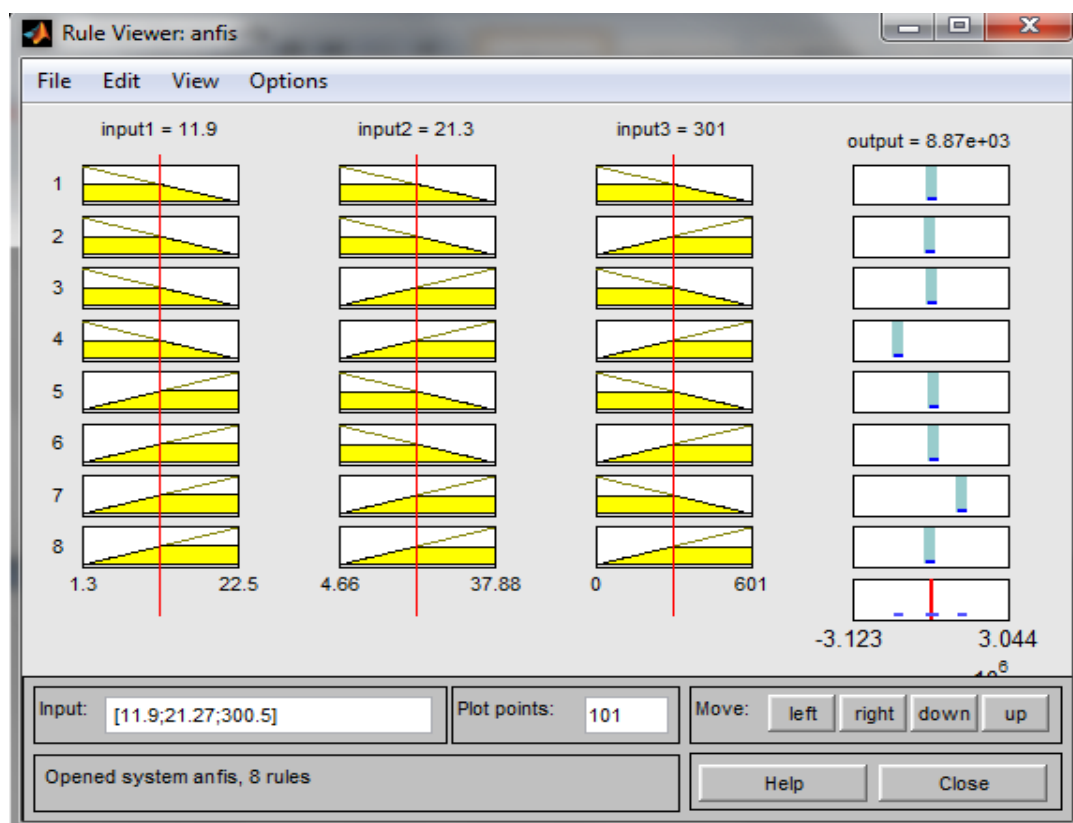
5.1.10 Μορφή Κανόνων (Rule Viewer)

Τα παρακάτω Διαγράμματα 5.16 και 5.17 παρουσιάζουν τη μορφή των κανόνων στην αρχή και στο τέλος της εκπαίδευσης, καθώς και τη μορφή της εξόδου συναρτήσεως της εισόδου.

Οι γραμμές αντιστοιχούν στους κανόνες και οι στήλες αντιστοιχούν στις συναρτήσεις συμμετοχής της κάθε εισόδου και εξόδου. Μετακινώντας την κόκκινη γραμμή, ο χρήστης έχει την δυνατότητα να μεταβάλλει τις τιμές των εισερχόμενων μεταβλητών και το σύστημα αυτόματα παράγει τις νέες τιμές εξόδου.



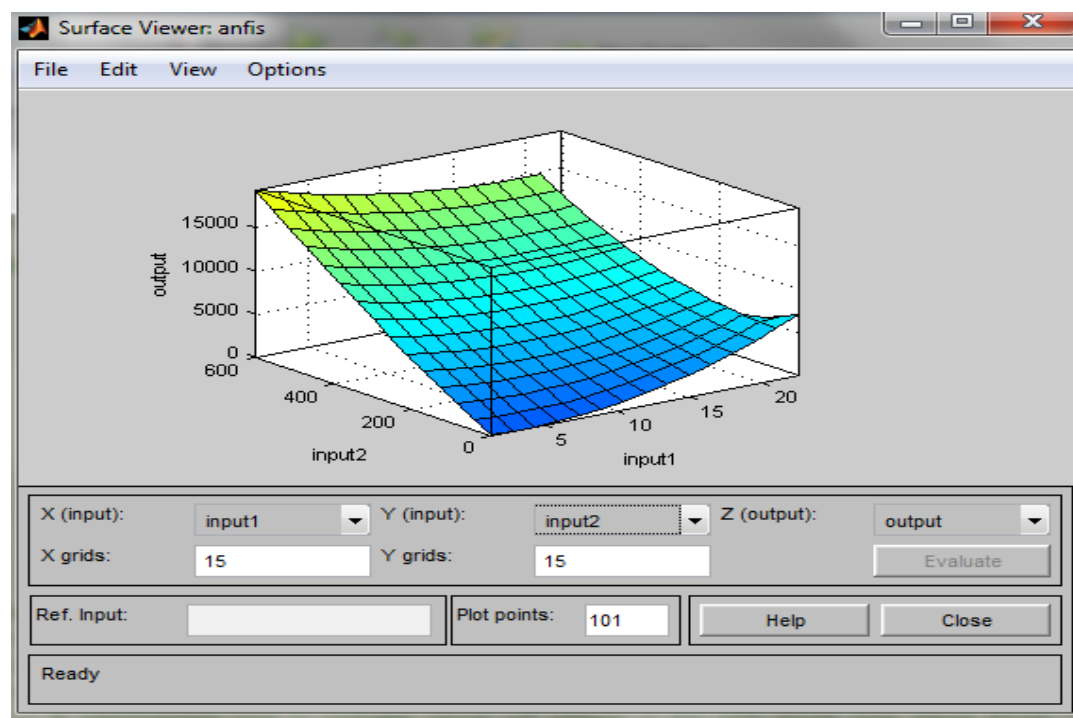
Διάγραμμα 5.16 ANFIS 2-4 Μορφή Κανόνων κατά τη Διαδικασία Εκπαίδευσης



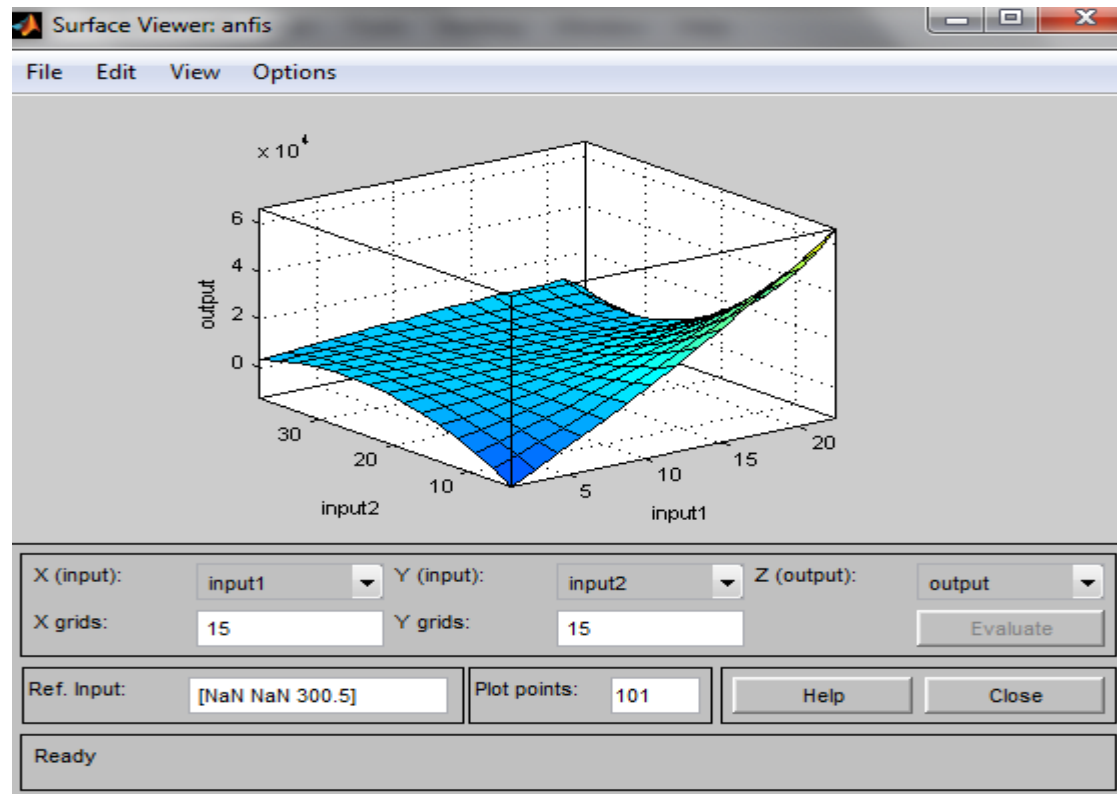
Διάγραμμα 5.17 ANFIS 3-4 Μορφή Κανόνων κατά τη Διαδικασία Εκπαίδευσης

5.1.11 Διαγράμματα Θέασης (ANFIS Surface Viewer)

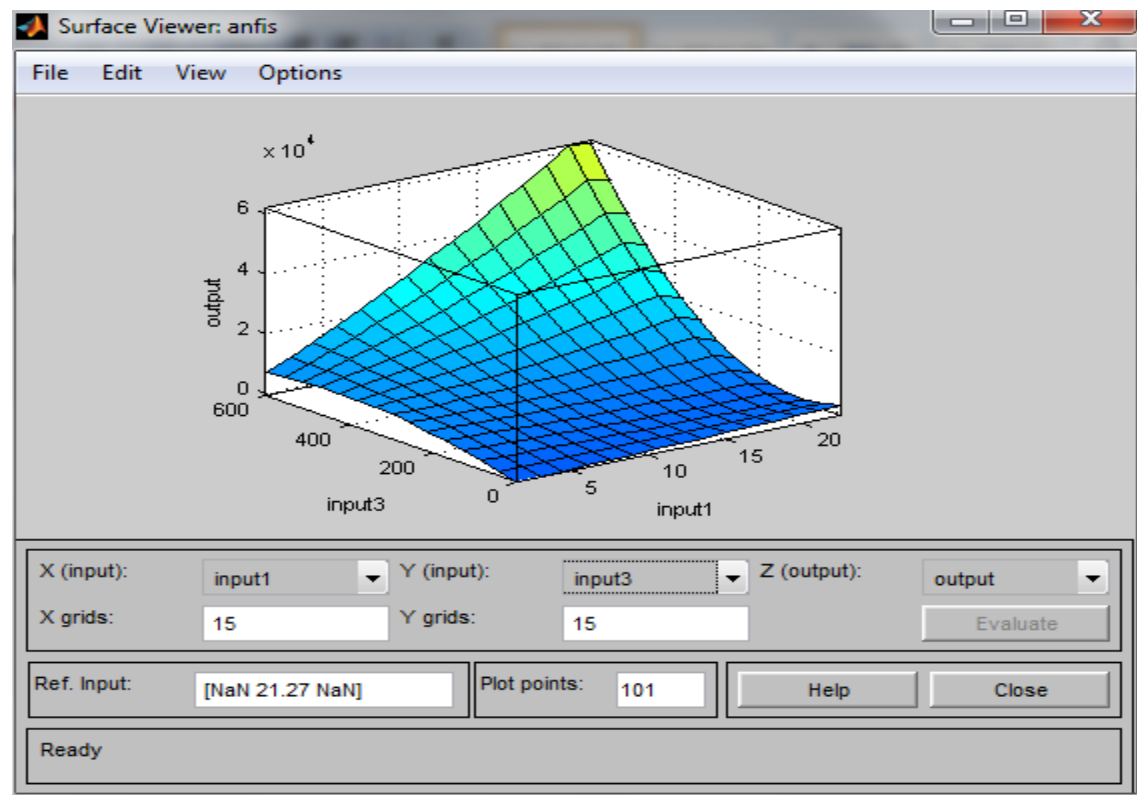
Στη συνέχεια έχουμε τα Διαγράμματα θέασης των ANFIS 2-4 (Διάγραμμα 5.18) και ANFIS 3-4 (Διαγράμματα 5.19, 5.20, 5.21).



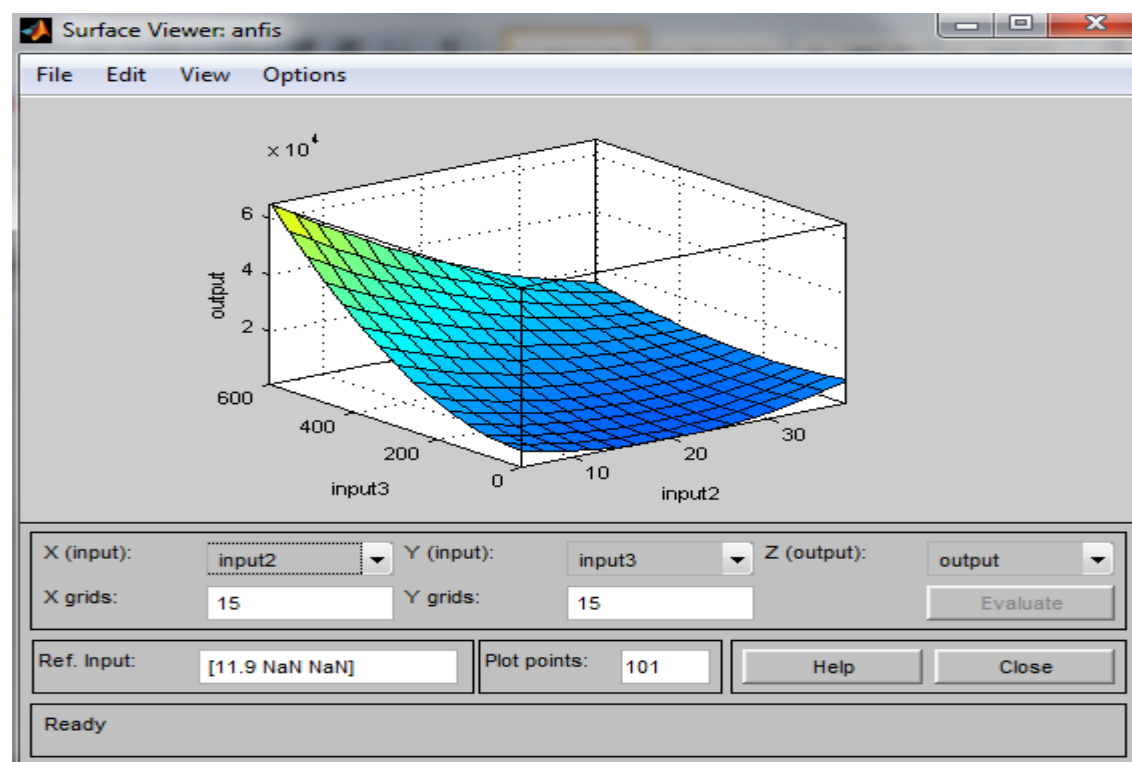
Διάγραμμα 5.18 Διάγραμμα Θέασης ANFIS 2-4



Διάγραμμα 5.19 Διάγραμμα Θέαςης ANFIS 3-4




Διάγραμμα 5.20 Διάγραμμα Θέαςης ANFIS 3-4




Διάγραμμα 5.21 Διάγραμμα Θέσης ANFIS 3-4

5.1.12 Πρόβλεψη Μοντέλων ANFIS


Σε αυτό το κομμάτι έχουμε τα Διαγράμματα πρόβλεψης των μοντέλων ANFIS 2-4 και ANFIS 3-4 σε σχέση με την πραγματική παράγωγή ηλεκτρικής ενέργειας της επόμενης μέρας (Διαγράμματα 5.22 και 5.24). Από την διάφορα των πραγματικών τιμών και των τιμών της πρόβλεψης, προκύπτει το σφάλμα πρόβλεψης αλλά και το διάγραμμα σφάλματος συναρτήσει των παρατηρήσεων (Διαγράμματα 5.23 και 5.25).




Διάγραμμα 5.22 Πραγματικές Τιμές και Πρόβλεψη ANFIS 2-4



Διάγραμμα 5.23 ANFIS 2-4 Σφάλμα Πρόβλεψης



Διάγραμμα 5.24 Πραγματικές Τιμές και Πρόβλεψη ANFIS 3-4



Διάγραμμα 5.25 ANFIS 3-4 Σφάλμα Πρόβλεψης

Συμπέρασμα

Όπως φαίνεται και από τα πιο πάνω Διαγράμματα, τα αποτελέσματα της πρόβλεψης για τα ANFIS 2-4 και ANFIS 3-4 είναι αρκετά καλά σε σχέση με τις πραγματικές τιμές αν και το δείγμα πρόβλεψης δεν είναι μεγάλο.

5.1.13 Αξιολόγηση των Μοντέλων Πρόβλεψης

Για την συνολική αξιολόγηση και των οκτώ μοντέλων πρόβλεψης έγινε υπολογισμός των επιμέρους σφαλμάτων πρόβλεψης. Υπολογίστηκαν με τους πιο κάτω μαθηματικούς τύπους:

το μέσο τετραγωνικό σφάλμα (MSE, Mean Square Error):

$$MSE = \frac{1}{N} \sum_{t=1}^N e_t^2$$

η ρίζα του μέσου τετραγωνικού σφάλματος (RMSE Root Mean Square Error):

$$RMSE = \sqrt{\frac{\sum_{t=1}^N e_t^2}{N}}$$

το μέσο απόλυτο σφάλμα (MAE Mean Absolute Error):

$$MAE = \frac{1}{N} \sum_{t=1}^N |e_t|$$

το μέσο απόλυτο ποσοστιαίο σφάλμα (MAPE, Mean Absolute Percentage Error):

$$MAPE = \frac{100}{N} \sum_{t=1}^N |e_t|$$

όπου

$$e_t = \frac{F_t - A_t}{A_t}$$

Πίνακας 5.2 ANFIS 2 Εισόδων - MSE - RMSE - MAE - MAPE

ERROR	ANFIS 2-1	ANFIS 2-2	ANFIS 2-3	ANFIS 2-4
MSE	9,7355e+05	8,0072e+05	5,8167e+05	4,0726e+05
RMSE	986,6884	894,8282	762,6724	638,1621
MAE	321,3825	307,7960	257,3213	232,8516
MAPE	9,7655	10,0537	9,9774	9,8998

Πίνακας 5.3 ANFIS 3 Εισόδων - MSE - RMSE - MAE - MAPE

ERROR	ANFIS 3-1	ANFIS 3-2	ANFIS 3-3	ANFIS 3-4
MSE	7,7251e+05	1,0005e+06	7,2601e+05	4,0929e+05
RMSE	878,9275	1,0002e+03	852,0613	639,7539
MAE	255,8102	345,2534	329,6696	221,3273
MAPE	10,3830	13,0638	13,1510	14,2921

Συμπεράσματα

Από τους παραπάνω Πινάκες (5.2, 5.3) είναι φανερό ότι γενικά τα μοντέλα με δυο εισόδους ANFIS 2 είχαν χαμηλότερα επιμέρους σφάλματα από τα μοντέλα με 3 εισόδους. Μόνο το μοντέλο ANFIS 3-1 παρουσιάζει χαμηλότερα σφάλματα από το ANFIS 2-1 εκτός από το μέσο απόλυτο ποσοστιαίο σφάλμα MAPE.

Επίσης το μοντέλο ANFIS 3-4 σε σχέση με το ANFIS 2-4 που επεξεργάστηκαν την ίδια χρονοσειρά δεδομένων, δεν έχουν μεγάλη διάφορα στη ρίζα του μέσου τετραγωνικού σφάλματος RMSE και το ANFIS 3-4 παρουσιάζει χαμηλότερο μέσο απόλυτο σφάλμα MAE.

Μια εξήγηση για την υπεροχή των μοντέλων ANFIS 2 είναι και οι αρκετά λιγότερες παράμετροι των και ίσως αν είχαμε μεγαλύτερη χρονοσειρά δεδομένων για εκπαίδευση, τα αποτελέσματα να ήταν διαφορετικά.

6^ο ΚΕΦΑΛΑΙΟ



ΣΥΜΠΕΡΑΣΜΑΤΑ

ΚΕΦΑΛΑΙΟ 6ο – ΣΥΜΠΕΡΑΣΜΑΤΑ

Τα δυο νευρο-ασαφή μοντέλα ANFIS 2 και ANFIS 3 που χρησιμοποιήθηκαν για τη πρόβλεψη παραγωγής ενέργειας της επόμενης μέρας (one step ahead) για τις τέσσερις ανεμογεννήτριες έδωσαν ικανοποιητικά αποτελέσματα.

Στο παρόν ερευνητικό έργο δεν έγινε σύγκριση με άλλα μοντέλα πρόβλεψης χρονοσειράς όπως το μοντέλο αυτοπαλινδρόμησης (Auto – Regression-AR), το μοντέλο αυτοπαλινδρόμησης κινούμενου μέσου (Auto – Regression moving average – ARMA). Αν και υπάρχουν προηγούμενες έρευνες που γίνεται σύγκριση και σε αρκετές το ANFIS υπερτερεί.

Επίσης, τα νευρωνικά δίκτυα μπορούν να δώσουν ακριβείς προβλέψεις σε αρκετά ζητήματα με το μειονέκτημα όμως της χρονοβόρας εκπαίδευσης και της απαίτησης μεγάλων δειγμάτων για εκπαίδευση σε σχέση με το ANFIS.

Το μονό σίγουρο είναι όσο θα αυξάνεται το μερίδιο των ανανεώσιμων πηγών στα ηλεκτρικά δίκτυα των χώρων ειδικά σε ευρωπαϊκό επίπεδο και με την τεχνολογία αποθήκευσης ηλεκτρικής ενέργειας να μην είναι ακόμη σε ικανοποιητικό επίπεδο, η σημασία πρόβλεψης της παραγωγής ενέργειας από ανανεώσιμες πηγές ενέργειας όπως η αιολική παραμένει σημαντική για την σταθερότητα και ασφάλεια των ηλεκτρικών δικτύων.

Επομένως υπάρχει το έδαφος για περαιτέρω ακαδημαϊκή ερευνα για το ANFIS ως ένα αξιόπιστο μοντέλο για πρόβλεψη παραγωγής αιολικής ενέργειας.

ΒΙΒΛΙΟΓΡΑΦΙΑ

ΒΙΒΛΙΟΓΡΑΦΙΑ

- [1] Διάφοροι Συγγραφείς *Αιολική Ενέργεια*. Δημοσίευση στην ιστοσελίδα https://el.wikipedia.org/wiki/Αιολική_ενέργεια
- [2] European Wind Energy Association (EWEA) (2023, February). *Wind energy in Europe 2022 – Statistics and the outlook for 2023 – 2027*. Published at <https://windeurope.org/intelligence-platform/product/wind-energy-in-europe-2022-statistics-and-the-outlook-for-2023-2027/>
- [3] Chang, W., Y. (2014). A Literature Review of Wind Forecasting Methods. *Journal of Power and Energy Engineering*, 2, 161-168.
- [4] Bhaskar, M., Jain, A., Srinath, N.V. (2010). *Wind Speed Forecasting: Present Status*. Paper presented at the International Conference on Power System Technology.
- [5] Kariniotakis, G., N., Marti, I., Nielsen, T., S., Giebel, G., Tambke, J., Waldl, I., Usaola, J., Brownsword, R., Kallos, G., Focken, U., Sanchez, I., Hatziaargyriou, N., Palomares, A.M., Frayssinet, P. (2006). *Advanced Short – term Forecasting of Wind Generation – Anemos*. IEEE on Trans Systems. Invited paper to special section on Power System Performance Issues Associated with Wind Energy.
- [6] Soman, S., S., Zareipour, H., Malik, O., Mandal, P. (2010). *A Review of Wind Power and Wind Speed Forecasting Methods With Different Time Horizons*. Paper presented at the Conference – North American Power Symposium (NAPS).
- [7] Kassa, Y., Zhang, J., H., Zheng, D., H., Wei, D. (2016). *Short Term Wind Power Prediction Using ANFIS*. Paper presented at the IEEE International Conference on Power and Renewable Energy (ICPRE).
- [8] Dernoncourt, F. (2013, January). *Introduction to Fuzzy Logic*, Massachusetts Institute of Technology.
- [9] King, R., E. (2004). *Ευφυής Έλεγχος*, Εκδόσεις Τζιόλα.
- [10] Cox, E. (1992, April). *The Seven Noble Truths of Fuzzy Logic*. Computer Design.
- [11] *Fuzzy Logic Toolbox™ User's Guide*. (1994 – 2024). The MathWorks, Inc.
- [12] Ατσαλάκης, Γ. (2006). *Νευρο – Ασαφή Συστήματα και Τεχνητή Ανάλυση για την Πρόβλεψη των Τιμών των Μετοχών*. Δημοσιεύτηκε στην ιστοσελίδα <https://epistimonikomarketing.gr>
- [13] Μωραϊτίδης, Θ. (2013). *Σύγκριση προβλέψεων παραδοσιακών και νέων τεχνολογιών πηγών ενεργείας*. Διπλωματική Εργασία. Πολυτεχνείο Κρήτης. Τμήμα Μηχανικών Παραγωγής και Διοίκησης.
- [14] Σαρρή, Μ. (2006). *Αξιοποίηση Ασαφούς Λογικής στη Διαμόρφωση Πλάνου Παραγωγής*. Διπλωματική Εργασία. Εθνικό Μετσόβιο Πολυτεχνείο. Σχολή Ηλεκτρολόγων Μηχανικών και Μηχανικών Υπολογιστών.
- [15] Βακουλη, Α. (2005). *Ασυνέπειες της Ασαφούς Λογικής*, Διπλωματική Εργασία. Πολυτεχνείο Κρήτης. Τμήμα Μηχανικών Παραγωγής και Διοίκησης.
- [16] Νικολάου, Ε. (2007). *Συγκριτική Ανάλυση και Εφαρμογή Γραμμικών, Μη – Γραμμικών και Νευρο – Ασαφών Μεθόδων, για τη Βραχυπρόθεσμη Πρόβλεψη Παραγωγής Ενεργείας από Αιολικά Πάρκα*. Διπλωματική Εργασία. Πολυτεχνείο Κρήτης. Σχολή



Ηλεκτρολόγων Μηχανικών και Μηχανικών Υπολογιστών.




- [17] Zadeh, L.A. (1989, March). *Knowledge Representation in Fuzzy Logic*. Published at the IEEE Transactions on Knowledge and Data Engineering (Volume:1, Issue:1).
- [18] Goodfellow, I., Bengio, Y., Courville, A., Haykin, S., Sivanandam, S., N. (2020). *Study Glance – Introduction to Neural Networks*. Published at <https://studyglance.in/nn/index.php>
- [19] Fausett, L. (1994). *Fundamentals of Neural Networks Architectures, Algorithms, and Examples*. Pearson Publishing.
- [20] Δεμερτζής, Κ. (2020). *Νευρωνικά Δίκτυα*. Διεθνές Πανεπιστήμιο της Ελλάδος. Σχολή Θετικών Επιστημών. Τμήμα Φυσικής. Πρόγραμμα Σπουδών Ηλεκτρολόγων Μηχανικών.
- [21] Jha, D., S., A. (2023). *Self – Supervised Learning and Its Applications*. Published at <https://neptune.ai/blog/self-supervised-learning>
- [22] Βλαχάβας, Ι. (2013). *Τεχνητή Νοημοσύνη. Τεχνητά Νευρωνικά Δίκτυα*. Τμήμα Πληροφορικής Αριστοτέλειου Πανεπιστημίου Θεσσαλονίκης.
- [23] Maad, M., M. (2018). *Artificial Neural Networks Advantages and Disadvantages*. Published at <https://www.linkedin.com/pulse/artificial-neural-networks-advantages-disadvantages-maad-m-mijwel>
- [24] Καλαμαράς, Χ. (2013). *Πρόβλεψη Τιμών του Ναυτιλιακού Βαλτικού Δείκτη Ξηρού Φορτίου (Baltic Dry Index), Μέσω Χρήσης Προσαρμοστικού Νευρο – Ασαφούς Συστήματος (Adaptive Neuro – Fuzzy System)*. Διπλωματική Εργασία. Πολυτεχνείο Κρήτης. Τμήμα Μηχανικών Παραγωγής και Διοίκησης.
- [25] Jang, Y., S., R. (1993). *ANFIS: Adaptive – Network – Based Fuzzy Inference System*. Paper presented at the IEEE Transactions on Systems Man and Cybernetics 23(3):(665 – 685).
- [26] Bonissone, P., P. (2002). *Adaptive Neural Fuzzy Inference Systems (ANFIS): Analysis and Applications*. Schenectady, NY USA. Available from <http://homepages.rpi.edu/~bonisp/fuzzy-course/99/L9/ANFIS.pdf>
- [27] Ατσαλάκης, Γ. (2006). *Συνοπτικές Σημειώσεις για την Λύση Ασκήσεων Τεχνολογικής Πρόβλεψης*. Πολυτεχνείο Κρήτης. Τμήμα Μηχανικών Παραγωγής και Διοίκησης.
- [28] Λέκου, Α. (2011). *Πρόβλεψη Εισαγόμενης Διασυνδεδεμένης Ενεργείας*. Μεταπτυχιακή Διατριβή. Πολυτεχνείο Κρήτης. Μεταπτυχιακό Τμήμα Μηχανικών Παραγωγής και Διοίκησης. Οργάνωση & Διοίκηση Επιχειρήσεων.
- [29] Atsalakis, G., Nezis, D., Zopounidis, C. (2010). *Neuro-Fuzzy Versus Traditional Models for Forecasting Wind Energy Production*. Department of Production Engineering and Management. Technical University of Crete. Chania. Crete. Greece.



ΠΑΡΑΡΤΗΜΑ



ΠΑΡΑΡΤΗΜΑ

ΓΡΑΦΙΚΕΣ ΠΑΡΑΣΤΑΣΕΙΣ - ΑΠΟΤΕΛΕΣΜΑΤΑ ANFIS 2-1






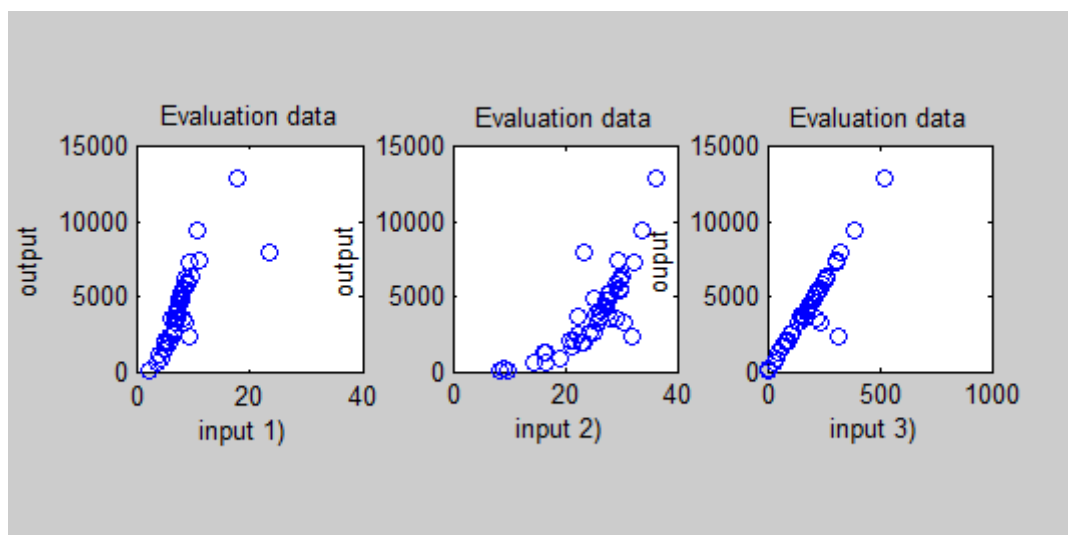










ΓΡΑΦΙΚΕΣ ΠΑΡΑΣΤΑΣΕΙΣ - ΑΠΟΤΕΛΕΣΜΑΤΑ ANFIS 3-1


















ΓΡΑΦΙΚΕΣ ΠΑΡΑΣΤΑΣΕΙΣ - ΑΠΟΤΕΛΕΣΜΑΤΑ ANFIS 2-2

















ΓΡΑΦΙΚΕΣ ΠΑΡΑΣΤΑΣΕΙΣ - ΑΠΟΤΕΛΕΣΜΑΤΑ ANFIS 3-2







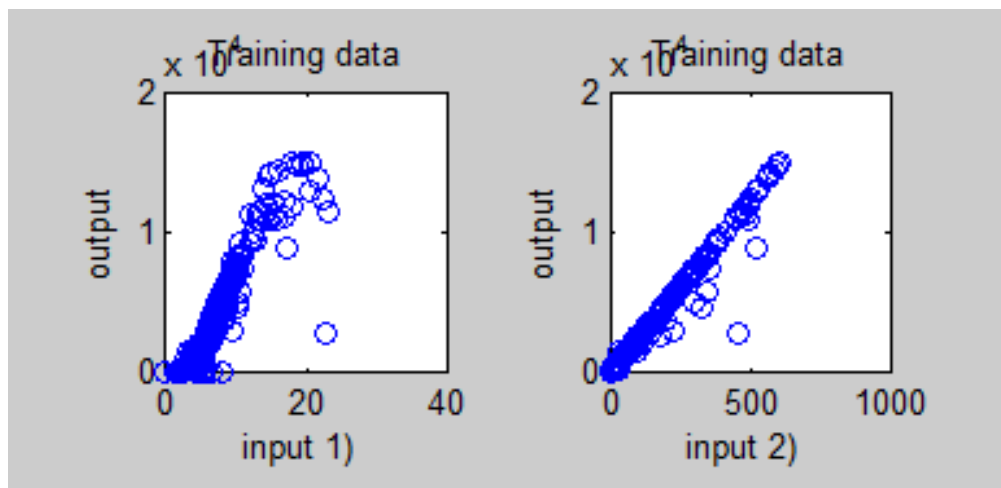










ΓΡΑΦΙΚΕΣ ΠΑΡΑΣΤΑΣΕΙΣ - ΑΠΟΤΕΛΕΣΜΑΤΑ ANFIS 2-3









ΓΡΑΦΙΚΕΣ ΠΑΡΑΣΤΑΣΕΙΣ - ΑΠΟΤΕΛΕΣΜΑΤΑ ANFIS 3-3

